



Sveučilište u Zagrebu

Fakultet organizacije i informatike

Mladen Konecki

**ADAPTABILNI SUSTAV POUČAVANJA
SVIRANJA BUBNJEVA S UGRAĐENIM
MEHANIZMOM PRILAGOĐENOGA
DINAMIČKOGA GENERIRANJA LEKCIJA
U STVARNOM VREMENU**

DOKTORSKI RAD

Varaždin, 2018.



Sveučilište u Zagrebu

Faculty of Organization and Informatics

Mladen Konecki

**ADAPTABLE DRUMS LEARNING SYSTEM WITH
SUPPORT FOR DYNAMIC AND ADAPTABLE
GENERATION OF LESSONS IN REAL TIME**

DOCTORAL THESIS

Varaždin, 2018.

PODACI O DOKTORSKOM RADU

I. AUTOR

Ime i prezime	Mladen Konecki
Datum i mjesto rođenja	7. veljače 1985., Pakrac
Naziv fakulteta i datum diplomiranja na VII stupnju	Fakultet organizacije i informatike, 21. listopada 2008.
Sadašnje zaposlenje	Fakultet organizacije i informatike

II. DOKTORSKI RAD

Naslov	Adaptabilni sustav poučavanja sviranja bubnjeva s ugrađenim mehanizmom prilagođenoga dinamičkoga generiranja lekcija u stvarnom vremenu
Broj stranica, slika, tabela, priloga, bibliografskih podataka	147 stranica, 67 slika, 28 tablica, 6 priloga, 154 bibliografska podatka
Znanstveno područje i polje iz kojeg je postignut doktorat znanosti	Društvene znanosti, Informacijske i komunikacijske znanosti
Mentori ili voditelji rada	Prof. dr. sc. Alen Lovrenčić Red. prof. art. Igor Lešnik
Fakultet na kojem je obranjen doktorski rad	Fakultet organizacije i informatike
Oznaka i redni broj rada	145

III. OCJENA I OBRANA

Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena tema	28. travnja 2015.
Datum predaje rada	9. travnja 2018.
Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena pozitivna ocjena rada	10. srpnja 2018.
Sastav povjerenstva koje je rad ocijenilo	Prof. dr. sc. Mirko Maleković Izv. prof. art. Ivana Bilić Prof. dr. sc. Dragutin Kermek
Datum obrane doktorskog rada	24. srpnja 2018.
Sastav povjerenstva pred kojim je rad obranjen	Prof. dr. sc. Mirko Maleković Izv. prof. art. Ivana Bilić Prof. dr. sc. Dragutin Kermek
Datum promocije	



Sveučilište u Zagrebu

Fakultet organizacije i informatike

Mladen Konecki

**ADAPTABILNI SUSTAV POUČAVANJA
SVIRANJA BUBNJEVA S UGRAĐENIM
MEHANIZMOM PRILAGOĐENOGA
DINAMIČKOGA GENERIRANJA LEKCIJA
U STVARNOM VREMENU**

DOKTORSKI RAD

Mentori:

Prof. dr. sc. Alen Lovrenčić
Red. prof. art. Igor Lešnik

Varaždin, 2018.



University of Zagreb

Faculty of Organization and Informatics

Mladen Konecki

ADAPTABLE DRUMS LEARNING SYSTEM WITH SUPPORT FOR DYNAMIC AND ADAPTABLE GENERATION OF LESSONS IN REAL TIME

DOCTORAL THESIS

Supervisors:

Prof. Alen Lovrenčić, Ph.D.
Full Professor Art. Igor Lešnik

Varaždin, 2018.

INFORMACIJE O MENTORIMA

Prof. dr. sc. Alen Lovrenčić je rođen u Čakovcu 8. rujna 1968. godine. Osnovnu školu i dva razreda opće srednje škole pohađao je u Čakovcu, a dva razreda usmjerene srednje škole u Varaždinu. Dodiplomski studij upisao je 1987. godine na Prirodoslovno-matematičkom fakultetu Sveučilišta u Zagrebu, smjer profesor matematike i informatike, gdje je diplomirao 10. lipnja 1993. godine te stekao stručno zvanje profesor matematike i informatike. Nakon završenog dodiplomskog studija radio je u Informacijsko-projektantskom centru Međimurje u Čakovcu i tvrtki TMT d.o.o. u Čakovcu. Znanstveni poslijediplomski studij upisao je 1995. godine na Fakultetu organizacije i informatike u Varaždinu, a 1999. godine obranio je znanstveni magistarski rad. Doktorirao je 2003. godine na Fakultetu organizacije i informatike Sveučilišta u Zagrebu.

Od 1997. godine zaposlen je u zvanju mlađeg asistenta na katedri za teorijske i primijenjene osnove informacijskih znanosti na Fakultetu organizacije i informatike u Varaždinu, 1999. godine izabran je u zvanje asistenta na istoj katedri, a 2004. godine stječe zvanje docenta. 2008. godine je izabran u znanstveno zvanje višeg znanstvenog suradnika i znanstveno-nastavno zvanje izvanrednog profesora. Od 2007. godine je pročelnik Katedre za teorijske i primijenjene osnove informacijskih znanosti. Od 1998. godine sudjelovao je na znanstvenom projektu Integracija baza znanja, pod vodstvom prof. dr. sc. Mirka Malekovića, koji je financiran od strane MZOŠ. Od 2002-2007. godine sudjeluje na projektu Formalizacija sustava poslovnih pravila financiranom od strane MZOŠ.

Od 2007. godine sudjeluje na znanstvenom projektu financiranom od MZOŠ, Semantičko modeliranje višeagentnih sustava pod voditeljstvom prof. dr. sc. Mirka Malekovića. Od 2008. godine je voditelj projekta MZOŠ pod nazivom Automatizacija postupaka u projektiranju informacijskih sustava. Vodio je Eureka projekt IS4 - SME Innovation Navigator pod brojem E!3521. Osim toga, sudjelovao je na ALIS projektima Popularisation of Science and Dissemination of Scientific Information i na TEMPUS projektu Aspects of Organization and Information Systems: Curriculum Development pod vodstvom prof. dr. sc. Blaženke Divjak. Bio je član tima za izradu CARNET-ovog referalnog centra za prijavu znanstvenih projekata na daljinu. Suautor je sveučilišnog udžbenika Sveučilišta u Zagrebu pod naslovom Diskretna matematika s teorijom grafova.

Redoviti profesor Sveučilišta u Zagrebu u trajnom zvanju Igor Lešnik djeluje na Muzičkoj akademiji u Zagrebu neprekidno od 1984. godine. Rođen je 23. veljače 1956. u Zagrebu. Od 1975. do 1979. studirao je i diplomirao udaraljke na Muzičkoj akademiji u Skopju, razred češki profesor Emil Klan. Od 1979. do 2013. vodio je dionicu udaraljki Simfonijskog orkestra Hrvatske radiotelevizije.

Kao državni stipendist Bugarske, od 1984. – 1985. završio je poslijediplomski studij, razred Prof. Dobri Paliev. Honorarno od 1984. do 1989. bio je predavačem predmeta udaraljke obligatno na Muzičkoj akademiji u Zagrebu. 1986. se usavršavao u Njemačkoj u Wurzburg-u, razred Prof. Siegfried Fink.

1989. utemeljio je studij udaraljki na Muzičkoj akademiji u Zagrebu te postao predavač glavnog predmeta udaraljke (honorarno). Od 1993. do 1995. djelovao je kao viši predavač MA (honorarno) te u razdoblju od 1995. do 2000. kao docent MA (honorarno).

Od 1. ožujka 2000. je u stalnom radnom odnosu na Muzičkoj akademiji u zvanju izvanrednog profesora udaraljki, 21. travnja 2004. reizabran je za izvanrednog profesora. U zvanje redovitog profesora Sveučilišta u Zagrebu izabran je 8. srpnja 2008. a za redovitog profesora u trajnom zvanju 2013.

Objavio je osam solističkih nosača zvuka, više od 30 skladateljskih radova te brojne članke u međunarodnim stručnim udaraljkaškim časopisima. Kao gostujući profesor održao je predavanja na brojnim sveučilištima Europe i svijeta. Imao je preko stotinu solističkih koncertnih nastupa na pet kontinenata a dobitnik je i brojnih domaćih te inozemnih nagrada: nagrada HDS-a "Vatroslav Lisinski", nagrada HDGU, nagrada "Josip Slavenski" kao voditelj ansambla "Supercussion", nagrada Milka Trnina, godišnja nagrada HDGPP i dr. Kao umjetnički voditelj i mentor udaraljkaškog ansambla biNg bang, dobitnik je nagrade "Ivo Vuljević", nagrade "Percussive Arts Society" i posebne rektorove nagrade (2005. i 2009.), nagrade "Marimba Projects Belgium" za poseban doprinos udaraljkaškoj pedagogiji. Ministarstvo kulture republike Francuske odlikovalo ga je 2003. godine naslovom Viteza Reda Umjetnosti i Književnosti.

SAŽETAK

U prvom dijelu ove doktorske disertacije dan je pregled znanstvene literature vezan uz primjenu računalne tehnologije u kontekstu učenja sviranja glazbenih instrumenata. Identificirani su postojeći koncepti na temelju kojih je kreiran novi konceptualni model adaptabilnog sustava poučavanja sviranja glazbenih instrumenata koji je nadograđen mehanizmom generiranja lekcija u stvarnom vremenu i mehanizmom za otklanjanje učestalih grešaka. Na temelju tog konceptualnog modela kreiran je prototip za učenje sviranja seta bubnjeva. U procesu evaluacije, model (odnosno prototip) je uspoređen s drugim alternativnim metodama samostalnog učenja sviranja seta bubnjeva. Rezultati su pokazali kako su korisnici novokreiranog sustava bili motiviraniji u odnosu na kontrolnu grupu koja je koristila video poduke. Što se tiče ishoda učenja, ostvarena je statistički značajna razlika u odnosu na obje kontrolne grupe.

Ključne riječi: učenje sviranja seta bubnjeva, adaptabilni sustav poučavanja, inteligentan sustav poučavanja, generiranje lekcija u stvarnom vremenu

ABSTRACT

In the first part of this research, a systematic overview of the scientific literature related to the use of computer technology in the context of learning how to play musical instruments has been given. Based upon existing concepts that have been identified, a new conceptual model of adaptable system for learning how to play musical instruments has been presented, which has been upgraded with the mechanism that generates lessons in real time and with the mechanism for elimination of common mistakes. Based upon this conceptual model, a prototype for learning how to play drums was created. In the evaluation process the model (or prototype) was compared with other alternative methods of self-learning how to play drums. The results have shown that users of newly created system were more motivated compared to the control group that used video tutorials. Considering playing skill level, the users that have used new system learned to play drums statistically significantly more successful than both control groups.

Keywords: learning how to play drums, adaptable learning system, intelligent learning system, real time lesson generation

PROŠIRENI SAŽETAK

U prvom dijelu ovog istraživanja predstavljen je pregled znanstvene literature o utjecaju slušanja i sviranja glazbe na čovjeka. Potom je prikazan pregled znanstvene literature o primjeni računalne tehnologije pri učenju osnovnih glazbenih znanja i vještina s posebnim naglaskom na primjenu računalne tehnologije kod samostalnog učenja sviranja glazbenih instrumenata. Kreiran je također pregled komercijalnih aplikacija u ovoj domeni kao i računalnih igara koje se bave sviranjem glazbenih instrumenata.

Na tim teorijskim osnovama identificirani su korišteni koncepti na temelju kojih je osmišljen konceptualni model adaptabilnog sustava za samostalno učenje sviranja glazbenih instrumenata nadograđen mehanizmom generiranja lekcija u stvarnom vremenu te mehanizmom otklanjanja učestalih pogrešaka u sviranju. Na temelju tog konceptualnog modela kao njegova instanca kreiran je prototip za samostalno učenje sviranja seta bubnjeva koji ima sve standardne elemente adaptabilnog sustava poučavanja: ekspertni model, studentski model, instrukcijski model, instrukcijsku okolinu i katalog pogrešaka.

U cilju utvrđivanja učinkovitost novokreiranog modela, provedena je evaluacija korištenjem njegovog prototipa. Sustav je uspoređen s alternativnim metodama samostalnog učenja sviranja seta bubnjeva kao što su učenje putem alternativnog računalnog softvera te učenje putem video poduke.

Ispitan je također utjecaj odabrane metode učenja na motivaciju korisnika te na razinu stečene tehničke vještine sviranja seta bubnjeva. Motivacija je izmjerena anketnim upitnikom o intrinzičnoj motivaciji na temelju teorije samoodređenja te anketnim upitnikom o stanju protoka na temelju Csikszentmihalyijeve teorije protoka. Razina stečene tehničke vještine sviranja seta bubnjeva se mjerila količinom točno odsviranih nota na završnom testu sviranja, količinom točno odsviranih uzoraka na završnom testu sviranja te ocjenom eksperta audio zapisa završnog testa.

Na temelju dobivenih rezultata zaključeno je kako je razina motivacije kod korisnika novog sustava bila statistički značajno veća u odnosu na korisnike koji su koristili video poduke za učenje sviranja seta bubnjeva. Glede razine tehničke vještine sviranja utvrđeno je da su

korisnici novog sustava naučili zadane vježbe na setu bubnjeva svirati statistički znatno točnije u odnosu na obje kontrolne grupe.

Ključne riječi: učenje sviranja seta bubnjeva, adaptabilni sustav poučavanja, inteligentan sustav poučavanja, generiranje lekcija u stvarnom vremenu

EXTENDED ABSTRACT

In the first part of this research, an overview of the scientific literature related to the impact of listening and playing music on people has been given. After that, an overview of scientific literature related to the application of computer technology in the domain of learning basic music knowledge and skills has been presented. Particular emphasis has been given on the application of computer technology in the field of learning how to play a musical instruments. An overview of commercial applications in this domain has also been given as well as an overview of computer games that teach one how to play a musical instruments.

Based upon these theoretical basics and existing concepts that have been identified a new conceptual model of adaptable system for learning how to play musical instruments has been presented, which has been upgraded with the mechanism that generates lessons in real time and with mechanism for elimination of common mistakes. Based upon newly created conceptual model a prototype has been created as an instance of this model, for self-learning how to play drums. Created model also includes all the standard elements of adaptable learning system: expert model, student model, instruction model, instructional environment and mistake catalog.

In order to conclude about the efficiency of newly created model, created prototype has been evaluated. The system has been compared with alternative methods of self-learning how to play drums: learning by using alternative software and learning by using video tutorials.

The impact of particular learning method on motivation and on the level of learned playing skill was measured. Motivation was measured by a survey based on self-determination theory and by the survey based on Csikszentmihaly's flow theory. The level of acquired playing skill was measured by counting amount of correct notes and the amount of correctly played rhythm patterns in the final exam and by expert's score of the audio record of the final exam.

Based on the obtained results, it has been concluded that the level of motivation of new system users was statistically significantly higher compared to the users who used video lessons to learn how to play drums. Considering playing skill level, the users that have used

new system have learned to play given drum exercises on drum kit statistically significantly more precisely compared to both control groups.

Keywords: learning how to play drums, adaptable learning system, intelligent learning system, real time lesson generation

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA.....	IV
POPIS TABLICA	VI
1. UVOD.....	1
1.1. Ciljevi istraživanja.....	2
1.2. Definirane hipoteze istraživanja	3
1.3. Ostvareni znanstveni doprinos istraživanja	4
1.4. Očekivani društveni doprinos istraživanja	4
1.5. Struktura doktorske disertacije	5
1.5.1. Design science - znanost o dizajnu	6
2. TEORIJSKI OKVIR.....	8
2.1. Utjecaji sviranja glazbe	8
2.1.1. Statistički podaci o glazbenoj edukaciji.....	10
2.2. Računalna tehnologiju u glazbenoj edukaciji	12
2.2.1. Razvoj audio sučelja	13
2.2.1.1. MIDI sučelje.....	15
2.2.1.2. ASIO protokol i VST	16
2.2.2. Umjetna inteligencija	16
2.2.2.1. Ekspertni sustavi	19
2.2.2.2. Računalom potpomognuto poučavanje i inteligentni sustavi poučavanja	21
2.2.2.3. Adaptabilni sustavi poučavanja.....	26
2.3. Računalni programi u glazbenoj edukaciji	27
2.3.1. Računalni sustavi učenja temeljnog glazbenog znanja	30
2.3.1.1. Continuator.....	30
2.3.1.2. Hyperscore	31
2.3.1.3. GNU Solfège	32
2.3.1.4. Auralia 4.....	33
2.3.1.5. LenMus.....	34
2.3.1.6. Musition 4	35
2.3.1.7. Music Ace 2	36
2.3.1.8. Musique Lab 2.....	37
2.3.1.9. Practica Musica 6	38
2.3.2. Računalni sustavi za učenje sviranja glazbenih instrumenata	39

2.3.2.1. PianoFORTE	39
2.3.2.2. Piano Tutor	40
2.3.2.3. Digital Violin Tutor	42
2.3.2.4. i-Maestro	43
2.3.2.5. IMUTUS (Interactive Music Tuition System)	44
2.3.2.6. VEMUS (Virtual European Music School)	46
2.3.3. Komercijalni proizvodi za učenje sviranja glazbenih instrumenata	47
2.3.3.1. DT-1 V-Drums Tutor i V-Drums Friend Jam	47
2.3.3.2. Playground Sessions	49
2.3.3.3. Piano Marvel	50
2.3.3.4. Bass Method i Guitar Method	51
2.3.3.5. My Guitar, My Electric Guitar, My Piano i My Violin	53
2.3.4. Računalne igre glazbenog sadržaja	54
2.3.4.1. Rock Band serijal	55
2.3.4.2. Rocksmith i Rocksmith 2014	56
2.4. Motivacijske teorije	58
2.4.1. Teorija protoka (Flow theory)	58
2.4.2. Teorija samoodređenja (Self-determination theory)	62
3. RAZVOJ KONCEPTUALNOG MODELA I PROTOTIPA	64
3.1. Ispitivanje inicijalnog interesa potencijalnih korisnika	65
3.2. Osnovni model adaptabilnog sustava poučavanja sviranja seta bubnjeva (ASPS-B) ...	67
3.3. Razvoj konceptualnog modela	71
3.3.1. Identifikacija pozitivnih karakteristika postojećih modela učenja sviranja	71
3.3.2. Postojeći modeli učenja sviranja	75
3.3.3. Predloženi konceptualni model učenja sviranja	76
3.4. Razvoj prototipa	78
3.4.1. Ulazni uređaji i generiranje zvuka	78
3.4.2. Instrukcijska okolina	81
3.4.2.1. Karakteristike grafičkog sučelja	81
3.4.2.2. Dizajn ASPS-B-a	86
3.4.3. Ekspertni model	94
3.4.3.1. Baza znanja	94
3.4.3.2. Mehanizmi zaključivanja	97
3.4.4. Studentski model	104
3.4.5. Instrukcijski model	107

4. EVALUACIJA MODELA I PROTOTIPA	109
4.1. Određivanje uniformnih grupa ispitanika.....	111
4.2. Proces evaluacije samostalnih metoda učenja sviranja seta bubnjeva	112
4.3. Rezultati analize motivacijskih upitnika.....	115
4.3.1. Intrinzična motivacija	116
4.3.2. Stanje protoka	118
4.3.3. Prihvatanje ili odbacivanje hipoteze H1	121
4.4. Rezultati analize testiranja vještine sviranja.....	121
4.4.1. Preciznost sviranja	122
4.4.2. Naučeni uzorci	124
4.4.3. Ocjena eksperta	128
4.4.4. Prihvatanje ili odbacivanje hipoteze H2.....	130
4.5. Ograničenja istraživanja i moguća daljnja istraživanja	131
5. ZAKLJUČAK.....	134
LITERATURA	136
PRILOZI	148

POPIS SLIKA

Slika 2.1. Povećanje inteligencije u odnosu na vrstu lekcija kod djece.....	8
Slika 2.2. Standardno mapiranje seta bubnjeva za MIDI protokol, kanal 10.	15
Slika 2.3. Globalna arhitektura ekspertnih sustava.....	19
Slika 2.4. Globalna arhitektura inteligentnih sustava poučavanja.....	24
Slika 2.5. Odnos između inteligentnih i adaptabilnih sustava poučavanja.....	27
Slika 2.6. Hyperscore grafičko sučelje: motivi i prozor za skiciranje.....	31
Slika 2.7. a) Grafičko sučelje za rad s intervalima b) Statistički podatci o vježbi.....	32
Slika 2.8. Auralia 4: Vježba prepoznavanja intervala.....	33
Slika 2.9. LenMus sučelje: Ispitni način rada vježbe prepoznavanja intervala.....	34
Slika 2.10. Musition 4: Teorija o notnim intervalima.....	35
Slika 2.11. Music Ace 2: glavni meni te lekcija slušanja i prepoznavanja ritmova.....	36
Slika 2.12. Musique Lab 2: Sučelje za anotaciju i sučelje za spektralnu analizu zvuka.....	37
Slika 2.13. Practica Musica 6: Prikaz jednostavne vježbe i naprednije vježbe.....	38
Slika 2.14. PianoFORTE: Sučelja za prikaz grešaka.....	39
Slika 2.15. Blok dijagram komponenti Piano Tutora.....	41
Slika 2.16. Sučelje sustava Digital Violin Tutor.....	42
Slika 2.17. i-Maestro: 3D vizualizacija pokreta gudala.....	44
Slika 2.18. IMUTUS: Greška označena strelicom uz opis greške popratnim tekstom.....	45
Slika 2.19. VEMUS: Anotacije različitih oblika.....	46
Slika 2.20. V-Drum Tutor: notni prikaz padajućih linija i standardna notacija.....	48
Slika 2.21. V-Drums Friend Jam: Sučelje za vrijeme sviranja pjesme.....	49
Slika 2.22. Playground Sessions: Prikaz bedževa i bodova nakon vježbe.....	50
Slika 2.23. Piano Marvel: Osnovna lekcija - učenje četvrtinki.....	51
Slika 2.24. Bass Method: Sučelje za sviranje pjesama s animiranim vratom gitare.....	52
Slika 2.25. Guitar Method: Pjesma u tablature prikazu.....	53
Slika 2.26. Mini igra za sviranje gitare, video lekcija za violinu, animirani vrat violine.....	54
Slika 2.27. Rock Band: Sučelje sviranja pjesme i MIDI kontroler za sviranje seta bubnjeva.....	55
Slika 2.28. Rocksmith 2014: Sučelje sviranja pjesme i mini igra.....	57
Slika 2.29. a) Ekvilibrij i b) emocionalna stanja kroz odnos vještine i izazova.....	58
Slika 3.1. Osnovni model adaptabilnog sustava za poučavanje sviranja seta bubnjeva.....	67
Slika 3.2. Idejni model strukture baze znanja i scenarij prolaska kroz bazu znanja.....	68
Slika 3.3. Način rada postojećih rješenja.....	75
Slika 3.4. Konceptualni model ASPS-B-a.....	76
Slika 3.5. Ulazni uređaji ASPS-B-a.....	78
Slika 3.6. Mapiranje uzoraka za hihat činelu.....	80

Slika 3.7. Redoslijed reprodukcije uzoraka unutar razine.....	81
Slika 3.8. Vrsta pomicanja interaktivnog notnog crtovlja.....	82
Slika 3.9. Animirana crta ili crta koja skače u taktu na dobe, pozicija detekcije.....	83
Slika 3.10. Standardno notno crtovlje u odnosu na apstraktno notno crtovlje.....	84
Slika 3.11. Vizualni prikaz seta bubnjeva.....	85
Slika 3.12. Povratna informacija u stvarnom vremenu.....	85
Slika 3.13. Početni ekran ASPS-B-a za odabir profila.....	86
Slika 3.14. Ekran za odabir lekcija.....	87
Slika 3.15. Vrste aktivnosti (slika iz uputa za korištenje sustava).....	88
Slika 3.16. Prozor za reprodukciju video zapisa.....	88
Slika 3.17. Prozor za vježbanje pojedinog uzorka.....	89
Slika 3.18. Prozor za sviranje ritmičkih uzoraka određene kategorije.....	90
Slika 3.19. Prozor vježbe za ponavljanje.....	91
Slika 3.20. Povratna informacija i motivacija za svaku aktivnost.....	92
Slika 3.21. Upute kako navigirati sustavom setom bubnjeva.....	93
Slika 3.22. Struktura ritmičkih uzoraka u bazi znanja.....	95
Slika 3.23. Prozor za demonstraciju sviranja ritmičkog uzorka.....	96
Slika 3.24. Vježbanje pojedinog ritmičkog uzorka.....	98
Slika 3.25. 8 taktova vježbe sviranja.....	99
Slika 3.26. Naučenost pojedinih ritmičkih uzoraka unutar kategorije.....	101
Slika 3.27. Katalog grešaka, klasifikacija grešaka.....	102
Slika 3.28. Desna ruka prati desnu nogu.....	103
Slika 3.29. Dinamika sviranja hihat činele.....	103
Slika 3.30. Klasifikacija uzoraka baze znanja.....	104
Slika 3.31. Ažuriranje studentskog modela za različite aktivnosti.....	106
Slika 4.1. Uzorci za inicijalnu procjenu sposobnosti korisnika.....	111
Slika 4.2. Odabir statističke metode za analizu rezultata.....	114
Slika 4.3. Histogrami po grupama - intrinzična motivacija.....	116
Slika 4.4. Histogrami po grupama - stanje protoka.....	119
Slika 4.5. Histogrami po grupama - točno odsvirane note.....	123
Slika 4.6. Histogrami po grupama - naučeni uzorci.....	126
Slika 4.7. Histogrami po grupama - ocjena eksperta.....	129

POPIS TABLICA

Tablica 2.1. Četiri osnovna pristupa u kreiranju inteligentnih sustava.....	17
Tablica 2.2. Računalom potpomognuto poučavanje.....	22
Tablica 2.3. Usporedba terminologije ASP-a i ISP-a.....	26
Tablica 3.1. Rezultati upitnika o inicijalnom interesu.....	65
Tablica 4.1. Deskriptivna statistika - intrinzična motivacija.....	116
Tablica 4.2. Testiranje normaliteta - intrinzična motivacija.....	117
Tablica 4.3. Kruskal-Wallisov test - intrinzična motivacija.....	117
Tablica 4.4. Kruskal-Wallisov test između prve i treće grupe - intrinzična motivacija.....	117
Tablica 4.5. Deskriptivna statistika - stanje protoka.....	118
Tablica 4.6. Testiranje normaliteta - stanje protoka.....	119
Tablica 4.7. Leveneov test - stanje protoka.....	119
Tablica 4.8. Jednofaktorska analiza varijanci - stanje protoka.....	120
Tablica 4.9. Fisherov LSD test - stanje protoka.....	120
Tablica 4.10. Deskriptivna statistika - točno odsvirane note.....	122
Tablica 4.11. Testiranje normaliteta - točno odsvirane note.....	123
Tablica 4.12. Leveneov test - točno odsvirane note.....	123
Tablica 4.13. Welchov test - točno odsvirane note.....	123
Tablica 4.14. Games-Howellov test - točno odsvirane note.....	124
Tablica 4.15. Deskriptivna statistika - naučeni uzorci.....	125
Tablica 4.16. Testiranje normaliteta - naučeni uzorci.....	126
Tablica 4.17. Leveneov test - naučeni uzorci.....	126
Tablica 4.18. Jednofaktorska analiza varijanci - naučeni uzorci.....	126
Tablica 4.19. Fisherov LSD test i Games-Howellov test - naučeni uzorci.....	127
Tablica 4.20. Deskriptivna statistika - ocjena eksperta.....	128
Tablica 4.21. Testiranje normaliteta - ocjena eksperta.....	129
Tablica 4.22. Leveneov test - ocjena eksperta.....	129
Tablica 4.23. Jednofaktorska analiza varijanci - ocjena eksperta.....	130
Tablica 4.24. Fisherov LSD test - ocjena eksperta.....	130

1. UVOD

Računalna tehnologija je sve prisutnija u svakoj domeni ljudskog djelovanja te je mnoge današnje djelatnosti gotovo nezamislivo raditi bez uporabe računalne tehnologije. Što se tiče područja glazbenog stvaralaštva, računala su pronašla svoju primjenu ponajprije u glazbenoj produkciji. Iako se računalna tehnologija koristi preko 20 godina u glazbenoj edukaciji, još uvijek nije zastupljena kao u nekim drugim domenama. Većina razvijenih računalnih programa koristi se kao pomoćno sredstvo u procesu poučavanja nekog aspekta glazbene teorije ili stjecana osnovnih glazbenih vještina kao što je pisanje nota, treniranje prepoznavanja melodijskih i ritmičkih uzoraka, harmonizacije i sl. No bez obzira na njihovo postojanje, njihova primjena u glazbenim školama i muzičkim akademijama je relativno skromna.

Na tržištu računalnih programa postoje i programi koji pomažu korisniku u savladavanju sviranja određenog glazbenog instrumenta. Većina tih programa je namijenjena učenju sviranja klavira, dok su drugi instrumenti vrlo slabo zastupljeni ili uopće ne postoje konkretna rješenja. Za učenje sviranja seta bubnjeva, što je glavni interes ovog rada, postoji samo jedan komercijalni proizvod a to je HD-1 Drum Tutor od poznatog poduzeća Roland koje proizvodi glazbenu opremu. Ono što je u ovoj domeni generalni nedostatak je to da je provedeno jako malo znanstvenih istraživanja koja istražuju koliko su zapravo ovi računalni programi uspješni u svojoj namjeni.

Pregledom znanstvene literature, uočena je potreba za razvojem kvalitetnog modela za učenje sviranja glazbenih instrumenata uz pomoć računalne tehnologije. U okviru ovog rada napraviti će se pregled postojećih koncepata i modela na kojima se temelje postojeći računalni programi koji pomažu korisnicima u savladavanju vještine sviranja određenog instrumenta. Na temelju tih koncepata i dodatnog istraživanja, napraviti će se novi poboljšani model koji će se temeljiti na pozitivnim karakteristikama postojećih modela te koji će također integrirati karakteristike adaptabilnih sustava poučavanja kako bi se proces učenja optimizirao u odnosu na postojeća rješenja. Kreirani model bit će razvijen u svrhu poboljšanja samostalnog učenja sviranja seta bubnjeva.

Ideja ovog rada nije konkurirati glazbenim školama jer računala još dugo neće moći zamijeniti čovjeka u procesu edukacije, ako ikad, pogotovo u sferama umjetnosti. Naprotiv, ideja je stvoriti kvalitetnu alternativu za sve one koji žele naučiti svirati set bubnjeva a nisu u mogućnosti ići u glazbene škole. Istraživanja su pokazala da je sviranje glazbenih instrumenta izuzetno dobro za razvoj čovjeka stoga je dobro poticati ljude da se na razne načine više bave glazbenim stvaralaštvom.

Na temelju osmišljenog modela, kreiran je računalni program putem kojeg je izvršena evaluacija, tj. usporedba s postojećim alternativnim načinima učenja sviranja seta bubnjeva kako bi se utvrdilo je li kreirani model uspješniji u poučavanju korisnika od postojećih rješenja te u kojoj mjeri.

1.1. Ciljevi istraživanja

U okviru ove doktorske disertacije, definirani su sljedeći ciljevi:

1. Napraviti pregled znanstvene literature u domeni primjene računalne tehnologije u svrhu pomoći savladavanja vještine sviranja glazbenih instrumenata.
2. Identificirati postojeće modele te njihove pozitivne karakteristike i utvrditi koje bi bile primjenjive u domeni poučavanja sviranja seta bubnjeva uz pomoć računalne tehnologije.
3. Osmisliti moguća poboljšanja u odnosu na postojeće modele te razviti novi konceptualni model adaptabilnog sustava poučavanja sviranja seta bubnjeva.
4. Izraditi prototip adaptabilnog sustava poučavanja sviranja seta bubnjeva na temelju osmišljenog konceptualnog modela.
5. Utvrditi utjecaj korištenja osmišljenog modela i kreiranog sustava na motivaciju korisnika za rad, brzinu savladavanja nastavnog gradiva i razinu kvalitete stečene vještine u usporedbi s alternativnim načinima samostalnog učenja sviranja seta bubnjeva.

1.2. Definirane hipoteze istraživanja

U nastavku su definirane hipoteze na temelju kojih je mjerena uspješnost osmišljenog modela, odnosno kreiranog prototipa.

H1. Adaptabilni sustav poučavanja sviranja seta bubnjeva (ASPS-B) će pozitivno utjecati na motivaciju učenika za rad u usporedbi s alternativnim pristupima samostalnog učenja sviranja seta bubnjeva.

H1A. Korisnici koji će koristiti ASPS-B će imati veću intrinzičnu motivaciju za rad u odnosu na korisnike koji će koristiti alternativne pristupe samostalnog učenja sviranja seta bubnjeva, izmjereno standardiziranim upitnikom na temelju teorije samoodređenja (self-determination theory) (Deci & Ryan, 2011).

H1B. Korisnici koji će koristiti ASPS-B će subjektivno percipirati da su bliže stanju "protoka", prema motivacijskoj teoriji protoka (Csikszentmihalyi), od korisnika koji će koristiti alternativne pristupe samostalnog učenja sviranja seta bubnjeva, izmjereno standardiziranim upitnikom za mjerenje stanja protoka (Jackson & Marsh, 1996).

H2. Adaptabilni sustav poučavanja sviranja bubnjeva (ASPS-B) će omogućiti korisnicima da nauče svirati bubnjeve uspješnije u usporedbi s alternativnim pristupima samostalnog učenja sviranja bubnjeva.

H2A. Korisnici koji će koristiti ASPS-B ostvarit će bolji prosječni rezultat u preciznosti sviranja od korisnika koji će koristiti alternativne pristupe samostalnog učenja sviranja seta bubnjeva.

H2B. Korisnici koji će koristiti ASPS-B će naučiti više ritmičkih uzoraka u planiranom vremenskom periodu od korisnika koji će koristiti alternativne pristupe samostalnog učenja sviranja seta bubnjeva.

H2C. Nezavisni ekspert koji neće imati informaciju o načinu učenja ocijenit će korisnike koji će koristiti ASPS-B u prosjeku višom ocjenom od korisnika koji će koristiti alternativne pristupe samostalnog učenja sviranja seta bubnjeva.

1.3. Ostvareni znanstveni doprinos istraživanja

Kroz ovaj rad postignut je napredak u domeni samostalnog učenja sviranja seta bubnjeva uz primjenu računalne tehnologije integracijom novih ideja i tehnologija koje su danas dostupne. Glavni znanstveni doprinos sažet je u nekoliko točaka:

1. Napravljen je pregled znanstvene literature iz domene primjene računalne tehnologije u svrhu samostalnog učenja sviranja glazbenih instrumenata.
2. Napravljen je kratak pregled komercijalnih proizvoda te računalnih igara koje se bave istom tematikom.
3. Identificirani su koncepti koji su se pokazali uspješnima u dosadašnjim istraživanjima.
4. Kreiran je novi konceptualni model adaptabilnog sustava poučavanja sviranja seta bubnjeva koji proširuje dosadašnje modele s komponentom prilagođenog dinamičkog kreiranja sadržaja lekcija i vježbi u stvarnom vremenu.
5. Izrađen je prototip sustava koji se temelji na osmišljenom konceptualnom modelu.
6. Kroz proces evaluacije, utvrđen je utjecaj korištenja osmišljenog modela, tj. kreiranog prototipa, na razinu stečene vještine, brzinu savladavanja vještine sviranja seta bubnjeva te motivaciju korisnika za rad u usporedbi s alternativnim načinima samostalnog učenja sviranja seta bubnjeva.

1.4. Očekivani društveni doprinos istraživanja

Ovo istraživanje ima potencijalno i veliki društveni doprinos. Pozitivni rezultati ovog istraživanja ukazuju na to da je kreiran novi funkcionalni model za poučavanje sviranja seta bubnjeva. Kreirani prototip je prvi adaptabilni sustav poučavanja sviranja seta bubnjeva koji integrira sve one komponente koje bi jedan takav sustav trebao imati.

Ovim radom se također želi popularizirati učenje sviranja seta bubnjeva te primjena računalne tehnologije u edukaciji sviranja seta bubnjeva. Jedan ovakav sustav mogao bi korisnike potaknuti da se počnu baviti sviranjem seta bubnjeva ili čak da nakon što se zainteresiraju za sviranje seta bubnjeva korištenjem kreiranog sustava, upišu glazbenu školu. Mnogi nemaju pristup glazbenim školama ili uz trenutne obaveze nemaju vremena ići u glazbenu školu, stoga je želja stvoriti kvalitetnu alternativu koja bi tim ljudima ipak omogućila da uče svirati.

Kreirani prototip je zamišljen kao sredstvo za samostalno učenje sviranja seta bubnjeva. No potencijalno, mogao bi se koristiti i kao pomoćno sredstvo u nastavnom procesu, posebice kod početnika. Nakon satova s profesorom, učenik odlazi kući vježbati te prilikom samostalnog vježbanja nema povratnu informaciju o tome radi li nešto dobro ili krivo. Ovakav sustav bi mogao pomoći početnicima i dati im povratnu informaciju o greškama koje rade. Na taj način bi se osvijestili što rade krivo te bi im to pomoglo da čim prije otklone greške koje rade.

1.5. Struktura doktorske disertacije

Ovaj rad je strukturiran u tri cjeline. U prvom dijelu, dan je teorijski okvir koji je potreban za razumijevanje problematike kojom se ovaj rad bavi. Dan je kratak osvrt na to zašto je dobro baviti se glazbom, prije svega sviranjem glazbenog instrumenta. Nakon toga slijedi kratak opis na koji način se računalna tehnologija može primijeniti u svrhu učenja sviranja glazbenih instrumenata. U ovom dijelu je napravljen pregled dosadašnjih istraživanja u domeni primjene računalne tehnologije u edukaciji sviranja glazbenih instrumenata. Spomenut će se i određeni komercijalni proizvodi kao i računalne igre koje se bave istom tematikom.

U drugom dijelu rada opisan je osmišljeni konceptualni model, njegove karakteristike i detalji. Također je opisan i razvoj prototipa koji će se temeljiti na konceptualnom modelu. Opisano je na koji način svaka pojedina komponenta prototipa funkcionira. Opisan je način na koji je znanje strukturirano u bazi znanja kao i mehanizmi zaključivanja novokreiranog modela. Opisano je koji se sve parametri prate tj. koji parametri su zapisani u modelu korisnika te na koji način instrukcijski model usmjerava korisnika u procesu učenja.

U trećem dijelu rada opisan je proces evaluacije uspješnosti sustava. Opisan je postupak kreiranja istraživačkih grupa, način provođenja evaluacije te na kraju su izneseni rezultati istraživanja te interpretacija tih rezultata. Također, dane su i neke smjernice za mogući daljnji razvoj sustava i mogućnosti za buduća istraživanja.

1.5.1. Design science - znanost o dizajnu

Većina znanstvenih istraživanja gdje se razvija neki informacijski sustav temelji se na jednoj od ove dvije paradigme: bihevioralna znanost (behavioral science) i znanost o dizajnu (design science). Paradigma bihevioralne znanosti pokušava razviti i verificirati teorije koje objašnjavaju ili predviđaju ponašanje čovjeka ili organizacije. Paradigma znanost o dizajnu pokušava proširiti granice ljudskih i organizacijskih sposobnosti kreiranjem novog artefakta. Obje paradigme su temelj domene informacijskih sustava, koje spajaju ljude, organizaciju i tehnologiju (Von Alen et al., 2004).

Istraživanje opisano u ovom radu je kreirano prema paradigmi znanost o dizajnu. Autori su definirali 7 osnovnih smjernica koje treba pratiti kako bi istraživanje zadovoljilo karakteristike ove paradigme (Von Alen et al., 2004):

1. Dizajniranje artefakta - rezultat istraživanja mora se temeljiti na nekom novom konstrukt, modelu ili metodi. Također, potrebno je kreirati instancu tog konstrukta, modela ili metode. U ovom radu razvijen je novi konceptualni model koji se temelji na postojećim modelima no koji je modificiran novim karakteristikama, te je napravljen prototip koji predstavlja instancu tog modela.
2. Relevantnost problema - cilj istraživanja mora biti razvoj informacijskog sustava koji rješava neki novi problem ili koji poboljšava postojeća rješenja nekog problema. U ovom radu razvijeno je bolje rješenje od postojećih rješenja u domeni računalnih sustava koji pomažu u samostalnom učenju sviranja seta bubnjeva. Rješenje koje će se razviti mora imati karakteristike inovativnosti. Model koji je razvijen u ovom radu ima ugrađene mehanizme kreiranja lekcija u stvarnom vremenu te dinamičko kreiranje vježbi za otklanjanje greški. Ovi koncepti nisu prije primijenjeni u domeni učenja sviranja glazbenih instrumenata.
3. Evaluacija dizajna - dizajn artefakta se mora evaluirati kroz jasne i poznate metode evaluacije. Najčešće je to neka studija slučaja ili eksperimentalno proučavanje artefakta u kontroliranim uvjetima. Testiranje se mora izvršiti na funkcionalnoj i strukturalnoj razini. Deskriptivni opisi se koriste u slučajevima kada se artefakt temelji na bazi znanja. Također se koristi i metoda scenarija kada se želi demonstrirati određena konkretna primjena. Model koji je kreiran u ovom radu je evaluiran kroz instancu prototipa. U suradnji s ekspertom, testirani su mogući scenariji kako bi se utvrdilo da se model ponaša korektno u svim definiranim slučajevima.


4. Doprinos istraživanja - Paradigma znanost o dizajnu definira tri osnovne skupine doprinosa: dizajnirani artefakt, teorijski temelji i metodologije. Dizajnirani artefakt je doprinos ako rješava neki novi problem ili postojeći problem na novi način. U slučajevima gdje se sustav temelji na bazi znanja, sama inovativna konstrukcija znanja može biti znanstveni doprinos. Doprinos ovog rada je izdizajnirani artefakt koji ima inovativne elemente u odnosu na postojeće artefakte. Baza znanja kreiranog sustava je također dizajnirana na jedinstven način.
5. Istraživačka strogost - Konstrukcija i evaluacija artefakta se mora temeljiti na jasnim i poznatim metodama razvoja i evaluacije. Dizajn i razvoj sustava temelji se na Corbettovom modelu razvoja inteligentnih sustava poučavanja (Corbett et al., 1997). Struktura adaptabilnog sustava poučavanja sastoji se od standardnih komponenti takvih sustava (Dabolins, 2012). Baza znanja je kreirana prema principima instrukcijskog dizajna, prema modelu Dick-a i Carrey-a (Dick & Carey, 2005). Specifične karakteristike sučelja su definirane kroz rezultate anketnih upitnika. Evaluacija je izvršena na standardiziranim anketnim upitnicima teorije protoka (Moneta, 2012) te teorije samoodređenja (Deci & Ryan, 2011). Također je korištena deskriptivna statistika, računanje srednjih vrijednosti i mjera disperzije, kao i inferencijalni statistički postupci za analizu varijance. U slučajevima gdje potrebne pretpostavke za jednofaktorsku analizu varijanci ne budu zadovoljene, koristit će se analogni neparametrijski test.
6. Dizajniranje kao proces traženja - Dizajniranje je proces traženja koji se provodi kako bi se otkrilo efikasno rješenje za neki problem. Traženje optimalnog rješenja je često neizvedivo za realne probleme informacijskih sustava. Heurističke strategije traženja najčešće daju izvediva i dobra rješenja koja se mogu implementirati u stvarnim okolinama. I u ovom radu dizajniranje artefakta je vršeno u iterativnim fazama gdje se koriste raspoloživa sredstva kako bi se postigao željeni rezultat.
7. Komunikacija istraživanja - istraživanje mora biti prezentirano na takav način da svima bude jasno kako artefakt funkcionira, i onima koji su informatički orijentirani i onima koji nisu. Zbog interdisciplinarnosti teme, opis svake komponente modela i cijelog sustava je takav da bude razumljiv svakome. Gdje je to potrebno, određeni dijelovi su opisivani s informatičkog gledišta no u takvim slučajevima uvijek postoji i deskriptivni opis kako bi svima bilo jasno kako model i sustav funkcioniraju.

2. TEORIJSKI OKVIR

2.1. Utjecaji sviranja glazbe

Brojna istraživanja su se bavila utjecajima sviranja glazbenih instrumenata na svirača. Inicijalno pitanje koje se postavlja je zašto bi uopće trebalo motivirati ljude da uče svirati bilo koji glazbeni instrument te ima li to utjecaj na razvoj čovjeka, te ako ima, kakav je taj utjecaj.

Istraživanja su pokazala da slušanjem glazbe ipak nije moguće dugoročno utjecati na povećanje kvocijenta inteligencije. Slušanjem određenog tipa glazbe ti efekti su bili kratkoročni i diskutabilni. No 2004. godine napravljeno je istraživanje koje je istraživalo utjecaj učenja lekcija iz glazbene i dramske umjetnosti kod djece od 6-7 godina. Slika 2.1. prikazuje da su djeca koja su bila izložena glazbenim lekcijama imala veće povećanje kvocijenta inteligencije od djece koja su bila izložena dramskim lekcijama ili koja nisu bila izložena nikakvim lekcijama. Sva djeca su imala povećanje kvocijenta inteligencije jer je istraživanje rađeno u periodu od 10 mjeseci. Razlika nije velika no ona je neupitna te kumulativno može predstavljati veliku razliku. Istraživanje je provedeno na 144 djece (Schellenberg, 2004). Rezultati sličnog istraživanja pokazuju da izlaganje glazbenim lekcijama kod djece može rezultirati povećanjem kvocijenta inteligencije i rezultirati boljim rezultatima u školi. Efekti su mali no dugotrajni (Schellenberg, 2006).



Slika 2.1. Povećanje inteligencije u odnosu na vrstu lekcija kod djece (Schellenberg, 2004)

Postoje i druga istraživanja koja su potvrdila da sviranje glazbenog instrumenta ili pjevanje u mladosti može rezultirati boljim akademskim uspjesima (Yang, 2015). Utjecaj glazbe se može primijetiti i u najranijem razvoju djece. Djeca koja su u svojoj najranijoj dobi bila izložena glazbenim interaktivnim lekcijama, zajedno sa svojim roditeljima, su bila više nasmijana, bolje su komunicirala te su puno ranije pokazala razumijevanje za visinu tona, ritam i harmoniju. Također je tu djecu bilo lakše umiriti te su bila manje uznemirena kada nije sve bilo po njihovom (Gerry et al., 2012).

Očito je da se bavljenjem glazbom izoštravaju slušne vještine, no one su primjenjive ne samo u glazbenoj domeni već i u drugim životnim situacijama (Kraus & Chandrasekaran, 2010). Istraživanja su također pokazala da su kod glazbenika bolje razvijene vizualno-motoričke sposobnosti, kao i brzina reagiranja te njihova pažnja može biti duže usmjerena na određenu aktivnost (Patston et al., 2007). Slično istraživanje je pokazalo kako sviranje glazbenih instrumenata rezultira dugoročnim poboljšanjem vizualno prostornih, verbalnih i matematičkih vještina (Schlaug et al., 2005). Još jedno istraživanje potvrdilo je da učenje glazbenih vještina kod djece rezultira povećanjem verbalne inteligencije. Čak 90% ispitanika u grupi je pokazalo napredak dok djeca u kontrolnoj grupi koja su učila likovnu umjetnost nisu pokazala nikakav značajan napredak (Moreno et al., 2011). Istraživanja su pokazala da sviranje glazbenih instrumenata može poboljšati izvršnu funkciju ili kognitivnu kontrolu kod čovjeka, što je uloga čeonog režnja u mozgu. Izvršna funkcija se sastoji od tri dijela: radne memorije, samokontrole te kognitivne fleksibilnosti, čiji je dio i sposobnost "promjene pravila". U glazbi, primjerice, svaki tonalitet ima svoja specifična obilježja, različiti ritmovi imaju svoja i sl. Sviranje i vježbanje se sastoji od koncentriranja, memoriranja, usmjerene pažnje, samodiscipline i sl. Stoga nije čudno da su upravo ti centri razvijeniji kod djece koja sviraju glazbene instrumente ili uče pjevati (Moreno et al., 2011).

Da bi stvar bila još i zanimljivija, utvrđeno je da je struktura mozga nešto drugačija kod ljudi koji se bave glazbom (Gaser & Schlaug, 2003). Kod glazbenika u pravilu ima više sive tvari u regiji koja spaja lijevu i desnu polutku mozga, veći je i primarni auditorni korteks (procesiranje zvuka), desni motorički korteks (posebice područje obje ruke) te lijevi i desni čeonni režanj (memorija, procesiranje harmonije). Već nakon 15 mjeseci učenja sviranja glazbenog instrumenta može se uočiti razlika (Hyde et al., 2009). No utjecaj nije vidljiv samo kod djece već se razlika uočila i kod starijih ljudi, u sposobnosti memoriranja i drugim kognitivnim vještinama (Gooding et al., 2014).

Naravno, treba spomenuti da sama svrha sviranja glazbenog instrumenta nije povećati kvocijent inteligencije ili mentalno i fizičko zdravlje, cilj je naučiti svirati glazbeni instrument radi njega samoga, radi ljubavi prema glazbi i glazbenom izričaju. No dobro je znati da postoji niz popratnih pozitivnih rezultata koji mogu proizaći iz sviranja glazbenog instrumenta te mogu biti korisni i u drugim područjima ljudskog djelovanja te mogu unaprijediti razvoj čovjeka u različitim aspektima.

2.1.1. Statistički podatci o glazbenoj edukaciji

Pitanje koje se može postaviti je koliko je relevantno baviti se ovim istraživanjem. Neka od pitanja koja se mogu postaviti su: je li interes za sviranjem glazbenih instrumenata u porastu ili opada, na koje sve načine ljudi uče svirati glazbene instrumente, da li su ljudi skloni koristiti računalnu tehnologiju u domeni glazbene edukacije i sl.

Statistički podatci pokazuju da sve više ljudi uči svirati glazbene instrumente. 2002. godine u Americi je bilo registrirano 15,74 milijuna glazbenika dok se 2010. godine taj broj popeo na 18,08 milijuna (Number of people playing a musical instrument, 2015). Glazbeni koncil Australije je proveo istraživanje i o tome koliko ljudi želi svirati glazbeni instrument. Dobili su vrlo zanimljive rezultate. U anketi su sudjelovali ljudi koji nisu nikada svirali niti jedan glazbeni instrument. Rezultati su pokazali da (Many people wish they had learnt to play, 2015):

- 75% ispitanika je željelo naučiti svirati neki glazbeni instrument
- 49% od njih još uvijek želi naučiti svirati neki glazbeni instrument
- 26% ispitanika misli da su prestari kako bi naučili svirati glazbeni instrument

Internacionalna asocijacija glazbenih proizvoda svake 3 godine radi istraživanje o prodaji glazbenih instrumenata u svijetu te odnosu ljudi prema sviranju glazbenih instrumenata. Na isto pitanje dobili su slične rezultate (NAMM, 2015):

- 85% ispitanika je željelo naučiti svirati neki glazbeni instrument
- 69% od njih još uvijek želi naučiti svirati neki instrument
- 20% ispitanika misli da su prestari kako bi naučili svirati glazbeni instrument

Ovi podatci govore da postoji veliki interes za sviranjem glazbenih instrumenata u svijetu te da zasigurno treba poraditi na načinima da se ovim ljudima omogući način da nauče svirati glazbene instrumente. Računalna tehnologija bi uvelike mogla pomoći u ostvarenju ovog cilja.

Danas sve više kućanstava ima glazbene instrumente (NAMM, 2015). 1997. godine 38% kućanstava je posjedovalo neki glazbeni instrument dok 2009. taj postotak je skočio na 58%. Glavni razlog je vjerojatno to što su instrumenti postali mnogo jeftiniji nego prije i dostupniji, no zasigurno je i povećanje interesa utjecalo na taj porast. Nadalje, 1997. godine, u 34% kućanstava su bila dva ili više svirača, dok je taj broj opet porastao na 43% 2009. godine. Odnos između spolova je relativno podjednak. Muških svirača ima svega 2% više. Čak 72% svirača svoje prve glazbene lekcije dobili su u dobi od 5-11 godina. U toj dobi sve više ljudi uči svirati glazbene instrumente: 2000. godine 29% svirača je počelo svirati u tim godinama dok se 2009. taj postotak popeo na 35%. Manje ljudi uči svirati u godinama od 18 - 24 dok su ostale dobne grupe podjednake.

Zanimljiv je i podatak da je u Americi 1982. godine čak 47% odraslih sudjelovalo u nekom obliku formalne glazbene edukacije dok se taj broj 2012. godine smanjio na 35,6% (Share of adults, 2015). To se može činiti pomalo kontradiktorno s informacijama koje su iznesene do sada. Odgovor leži u tome da je s pojavom Interneta znanje postalo svima dostupno te su se pojavili novi načini učenja sviranja glazbenih instrumenata, prvenstveno korištenjem Interneta i računalne tehnologije. 2000. godine 25% svirača je svoju prvu glazbenu lekciju učilo u školi dok je 2009. taj postotak pao na 22%. S druge strane, 2000. godine 14% učenika je učilo svirati samostalno dok je taj postotak porastao 2009. godine na 20%. Zbog dostupnosti znanja samostalno učenje postaje sve više zastupljena metoda učenja. Konkretno vezano za Internet, 2003. godine 20% učenika je koristilo Internet za učenje sviranja instrumenta dok je 2009. godine taj postotak porastao na 30%. To je gotovo trećina svih ljudi koji uče svirati glazbene instrumente.

Postoji veliko slaganje oko utjecaja sviranja glazbenog instrumenta na pojedinca. Podatci iz 2009. godine pokazuju da (NAMM, 2015):

- 97% ispitanika smatra da je glazbeni instrument dobro sredstvo izražavanja
- 95% ispitanika smatra da je sviranje zabavno
- 94% ispitanika smatra da sviranje opušta

- 88% ispitanika smatra da sviranje glazbenog instrumenta uči samodisciplini
- 59% ispitanika smatra da sviranje glazbenog instrumenta razvija kreativnost
- 45% ispitanika smatra da sviranje pomaže u intelektualnom razvoju

Zanimljivo je da je najmanji postotak vezan uz intelektualni razvoj dok su upravo znanstvena istraživanja pokazala da sviranje glazbenih instrumenata može i ima utjecaj na razne kognitivne sposobnosti čovjeka.

Što se tiče popularnosti samih instrumenata, dobiveni su sljedeći rezultati (NAMM, 2015):

- 30% učenika želi svirati gitaru, električnu gitaru ili bas gitaru
- 27% učenika želi svirati klavir
- 9% učenika želi svirati set bubnjeva ili perkusije
- 34% želi svirati nešto drugo

Očekivano, gitara i klavir su izuzetno popularni instrumenti dok je set bubnjeva nešto manje zastupljen. Ipak, 9% u odnosu na broj instrumenata i nije tako loša statistika. Zanimljivo je i da 75% svirača samo bira koji će instrument svirati dok za preostalih 25% odlučuje netko drugi.

Ono što se može zaključiti je da danas postoji veliki interes mnogih ljudi za učenjem sviranja glazbenih instrumenata. Statistika pokazuje da postoji veliki broj ljudi koji je želio naučiti svirati neki glazbeni instrument a nikada nije naučio. Otvaranjem novih mogućnosti učenja sviranja glazbenih instrumenata bi se možda mogli zahvatiti i neki od tih ljudi te im omogućiti da nauče svirati željeni glazbeni instrument.

2.2. Računalna tehnologiju u glazbenoj edukaciji

U današnje vrijeme, tehnologija je sve prisutnija u svim ljudskim djelatnostima, tako je usko povezana i s glazbenim svijetom i u području edukacije. U svojoj knjizi Burnard ističe kako je nužno danas uvoditi računalnu tehnologiju u glazbenu edukaciju (Finney & Burnard, 2010). Ističe kako je potrebna inovativnost u radu te reforma školskog programa. Školski programi su sve udaljeniji od današnje popularne glazbe i to je jedan od razloga zašto opada interes za tu vrstu predmeta u školama. Smatra da će se, ako se borba izgubi već u školama, teško na

druge načine to nadoknaditi. Također ističe da je računalna tehnologija ključan faktor u obogaćivanju glazbenih edukativnih programa, kako se treba odmaknuti od standardnih, ustaljenih metoda rada te isprobati nove inovativne metode koje će biti multimedijски bogatije.

Današnja računalna tehnologija je hardverski dovoljno zrela kako bi podržala izradu računalnih sustava koji bi mogli biti korisni u glazbenoj edukaciji. Razvijena su kvalitetna audio sučelja koja omogućuju vrhunsku kvalitetu zvuka i odaziv u stvarnom vremenu. Razvijena su sučelja koja omogućavaju komunikaciju između glazbenog instrumenta i računala. Računala su također u stanju oponašati ljudsko ponašanje primjenom koncepata umjetne inteligencije. Ekspertni sustavi su računalni sustavi koji su u stanju oponašati odlučivanje eksperta u određenoj domeni te se smatraju prvim pravim računalnim sustavima koji su uspješno primijenili koncepte umjetne inteligencije (Neapolitan, 2012).

2.2.1. Razvoj audio sučelja

Prvo audio sučelje koje je moglo generirati zvuk u računalu osobne primjene razvijeno je 1981. godine te se nalazilo u računalima Commodore C64/128. U programerskom priručniku za Commodore C64 piše: Sučelje za zvuk nudi veliki raspon visoke rezolucije kontrole frekvencije, boje tona i dinamike" ("Commodore 64, 2015). Ovo sučelje je moglo proizvoditi 3 zvuka odjednom, svaki glas se koristio neovisno, primjerice, jedan bi bio zvuk malog bubnja, jedan zvuk pedal basa dok bi treći glas svirao melodiju. Dugo vremena ovo sučelje je bilo najbolje sučelje na tržištu.

Otprilike u isto vrijeme IBM je razvio svoje audio sučelje poznato pod imenom "PC Speaker" (The birth of the IBM PC, 2015). To je bio uređaj koji je mogao reproducirati primitivne zvučne efekte. PC Speaker je mogao proizvesti samo jedan zvuk istovremeno. Stoga, ako se želio dobiti efekt akorda, izuzetno brzo su se svirali tonovi akorda jedan za drugim kako bi se dobio privid polifonije.

Prvi veći pomak dogodio se pojavom zvučnih kartica 1987. godine. "AdLib Music Synthesiser" bila je prva zvučna kartica koja se mogla ugraditi u računalo te se temeljila na Yamaha YM3812 FM čipu koji je mogao sintetizirati različite zvukove instrumenata (AdLib, 2015). Kartica je mogla proizvoditi 6 melodijskih i 5 ritmičkih zvukova istovremeno. 1990.

godine pojavio se i prvi MIDI sekvencer no u vrlo primitivnom obliku. Alternativna tehnologija bio je Rolandov MT-32 sintesajzer no on nije bio u obliku zvučne kartice već kao eksterni uređaj koji se spajao preko posebne kartice (MPU-401) koju je također razvio Roland (Roland MT-32, 2015). MPU-401 je bila prva kartica koja je imala MIDI sučelje za računalno.

Povećanjem kapaciteta diskova na računalima omogućeno je stvaranje digitalnog zvuka koji bi bio pohranjen na disku i koji bi se reproducirao. Počeli su se razvijati prvi analogno digitalni pretvarači zvuka. Uslijedila je serija zvučnih kartica pod imenom "SoundBlaster" koja je pod operativnim sustavom Windows 3.0 mogla snimati i reproducirati zvuk u 8-bitnoj kvaliteti s brzinom uzorkovanja od 22kHz (Sound Blaster, 2015). 1992. godine izlazi prva SoundBlaster kartica koja je nudila 16-bitnu reprodukciju i snimanje zvuka. Ove kartice su prije svega bile usmjerene igračima igara, imale su na sebi ulaz za "joystick" no taj ulaz se mogao koristiti za bilo koji MIDI kontroler.

1995. godine razvijena je komponenta DirectSound koja je sastavni dio Microsoft DirectX-a (DirectSound, 2015). DirectSound je bio poprilično inovativan svojevremeno jer je omogućavao simultane tokove audio podataka koji su se slali na zvučnu karticu. Iako je omogućavao direktnu komunikaciju aplikacija sa zvučnom karticom, vremensko kašnjenje zvuka kretalo se u rasponima od 50 do 80 milisekundi što nije bilo dovoljno za profesionalne audio aplikacije koje bi radile u stvarnom vremenu. DirectSound se koristio u operacijskim sustavima Windows 95 i Windows XP.


Operacijski sustavi Windows Vista te Windows 7 su donijeli novu arhitekturu za rad sa zvukom koja se zove WASAPI (WASAPI, 2015). WASAPI omogućava korištenje naprednijih audio sučelja koja imaju više kanala. Jednako tako, svaka aplikacija je imala svoju zasebnu kontrolu toka zvuka. Također je uveden i ekskluzivan način rada gdje se preskaču posrednički slojevi te aplikacija direktno komunicira sa zvučnom karticom. Kašnjenje zvuka je bilo moguće u tom načinu rada svesti ispod 10ms.

Podrška za obradu zvuka s izuzetno malim latencijama nikada nije bila prioritet u razvoju Windows operacijskih sustava. No Microsoft je u svom najnovijem operacijskom sustavu, Windows 10 najavio nadogradnju podrške za audio s malim kašnjenjem te tvrdi da će putem novih programskih sučelja latencija biti spuštена ispod 6ms (Enabling great audio, 2015).

2.2.1.1. MIDI sučelje

MIDI sučelje je digitalno sučelje za glazbene instrumente. Ovaj protokol je inicijalno razvijen 1983. godine kada su se pojavili sintesajzeri u glazbenoj industriji. Ovim protokolom se ne šalje zvuk već se šalju informacije o notama, kao što su visina tona, dužina tona, dinamika i sl. Također je moguće proslijediti informacije o brojnim parametrima tona kao što su glasnoća, vibrato, pozicija u stereo spektru, podatci o tempu i sl. Jedna MIDI konekcija može prenositi najviše 16 kanala informacija (Loy, 1985). Danas je ovaj protokol pronašao brojnu primjenu. Koristi se u kontroliranju osvjetljenja, glazbenoj produkciji, računalnoj animaciji i mnogim drugim domenama (Guerin, 2005).

1991. godine definiran je standard mapiranja MIDI instrumenata (General MIDI, 2015). Točno je specificirano za svaku notu koja je njena pozicija te na kojim kanalima se nalazi koji instrument. Definiran je standard od 128 učestalih instrumenata tako da prilikom reprodukcije MIDI zvučnih zapisa na različitim uređajima čujemo iste instrumente, bez obzira na njihov specifičan zvučni zapis na svakom pojedinom uređaju. Primjerice, set bubnjeva se nalazi na kanalu 10 a standardno mapiranje prikazano je na slici 2.2.



Slika 2.2. Standardno mapiranje seta bubnjeva za MIDI protokol, kanal 10.

Ako proizvođači električnih bubnjeva prate ovaj standard, tada će svi električni setovi bubnjevi, bez obzira na model i proizvođača, slati MIDI poruke na istom kanalu i na istim pozicijama za određeni element u bubnjarskom setu. To olakšava stvar jer je prilikom

kreiranja računalnog sustava dovoljno napraviti jedno mapiranje i svi bubnjevi će ispravno slati poruke i komunikacija će funkcionirati.

2.2.1.2. ASIO protokol i VST

Primarni razlog razvoja audio sučelja u računalima bile su multimedijske aplikacije, i to ponajprije računalne igre. Firma Steinberg je prva krenula u razvoj profesionalnih audio sučelja i aplikacija čija je primarna primjena audio produkcija. Osnovana je 1984. godine (Steinberg Story, 2015) te su iste godine razvili svoj prvi MIDI sekvencer. Revolucionarna godina razvoja bila je 1996. kada je predstavljen VST (Virtual Studio Technology) koja se temeljila na razvijenom ASIO (Audio Stream Input/Output) protokolu.

ASIO protokol je upravljački program zvučne kartice koji je razvila tvrtka Steinberg koji omogućava izuzetno niske latencije u komunikaciji sa zvučnom karticom (2-6ms) te vrhunsku kvalitetu zvuka (Steinberg, 2013). ASIO je vrlo brzo postao standard u audio produkciji te danas svako profesionalno audio sučelje na Windows platformi ima svoje ASIO upravljačke programe koji omogućuju rad sa vrlo niskom latencijom koja je preduvjet za razvoj glazbenih aplikacija.

VST je programsko sučelje koje omogućava stvaranje "virtualnih" instrumenata i glazbenih efekata integracijom s računalnim programima za snimanje zvuka. Ovo sučelje je vrlo brzo postalo standard u razvoju računalnih virtualnih glazbenih instrumenata, bilo da se radi o razvoju replika analognih instrumenata ili razvoju potpuno novih instrumenata. Virtualni instrumenti se "sviraju" putem MIDI sučelja te zvuk se reproducira kao digitalni zvučni signal. Iako se u ovom radu neće izraditi samostalni virtualni instrument, kreirani prototip će imati mnoge karakteristike računalnog virtualnog instrumenta (Steinberg Technologies, 2015).

2.2.2. Umjetna inteligencija

Područje umjetne inteligencije se bavi razumijevanjem inteligentnih entiteta te stvaranjem inteligentnih agenata. Postoje brojne definicije umjetne inteligencije te one variraju između dvije dimenzije: jedna je misaoni proces ili zaključivanje a druga je ponašanje. Također, kreiranje agenta se može voditi time da se uspoređuje s performansama čovjeka ili da teži

racionalnom, idealnom konceptu. Prema ovim svojstvima, moguće je zauzeti 4 osnovna pristupa kreiranja inteligentnih sustava koja su prikazana u tablici 2.1.

Tablica 2.1. Četiri osnovna pristupa u kreiranju inteligentnih sustava

<p>Sustav koji razmišlja poput čovjeka.</p> <p>"Automatizacija aktivnosti koje su povezane s ljudskim razmišljanjem, aktivnosti poput donošenja odluka, rješavanje problema, učenja..."</p> <p>(Bellman, 1978)</p>	<p>Sustav koji je racionalan.</p> <p>"Proučavanje izračuna koji omogućavaju percepciju, zaključivanje i djelovanje." (Winston, 1992)</p>
<p>Sustav koji se ponaša poput čovjeka.</p> <p>"Proučavanje kako učiniti da računala mogu raditi stvari, u kojima je trenutno, čovjek bolji." (Rich & Knight, 1991)</p>	<p>Sustav koji se ponaša racionalno.</p> <p>"Ogranak računalne znanosti koji se bavi automatizacijom inteligentnog ponašanja." (Luger & Stubblefield, 1993)</p>

Glavni cilj ovog područja je kreiranje sustava koji bi imao svojstva generalnog inteligentnog ponašanja, sustava koji bi mogao izvršavati brojne kognitivne zadatke, primjenjivati razne metode rješavanja problema, koji bi mogao prikladno prikazivati rezultate svog djelovanja te koji bi mogao učiti o svim aspektima raznih zadataka te primjenjivati naučeno znanje. Postoje i pokušaji kreiranja takvih arhitektura (Laird et al., 1987; Goertzel, 2007) no do danas takav sustav nije uspješno kreiran.

Postoji nekoliko glavnih kategorija primjene umjetne inteligencije (Russell & Norvig, 1995):

- Rješavanje problema: inteligentni agenti mogu djelovati tako da im se zadaju ciljevi te oni razmatraju nizove koraka koji bi doveli do ostvarenja tih ciljeva. Definiranje cilja se najčešće naziva *problem* a proces dolaska do cilja *pretraživanje* jer se najčešće koriste razne varijante algoritama pretraživanja kako bi se došlo do zadanog cilja.
- Znanje i zaključivanje: inteligentni sustavi se mogu temeljiti i na principu kreiranja baze znanja gdje se pohranjuju sve potrebne informacije o nekom problemu iz realnog svijeta. Na temelju informacija iz baze znanja vrši se zaključivanje prema ulaznim parametrima za definirani problem. Kreiranje kvalitetne baze znanja koja će uključiti sve moguće situacije i varijante problema je često vrlo težak zadatak kao i kreiranje različitih pristupa rješavanja problema.
- Planiranje: percipiranjem svoje okoline, inteligentni agent stvara sliku svijeta u kojem se nalazi. Kada se nakon toga agentu definira cilj, agent primjenjuje prikladan

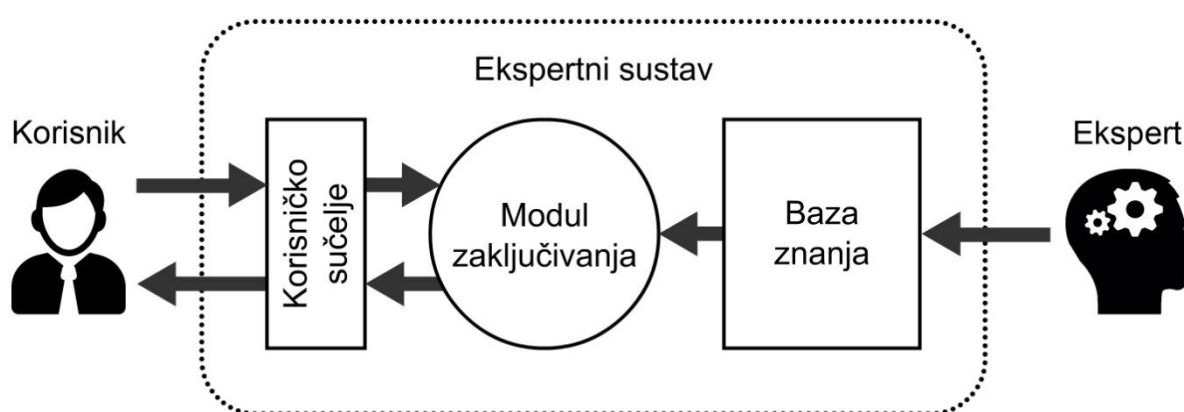
algoritam planiranja kako bi stvorio plan koraka kako doći do cilja. Agent tada može i izvršiti plan, korak po korak.

- Neizrazito znanje i zaključivanje: postoje mnogi problemi kod kojih je znanje neizrazito (dijagnoza bolesti u medicini, popravak kvara automobila i sl.). Kod neizrazitog znanja jako je teško odrediti uzrok i posljedicu i direktan utjecaj među parametrima. Kod ovakvih vrsta problema se može govoriti o razini vjerovanja da je nešto povezano. Glavna metoda koja se bavi ovakvim problemima je teorija vjerojatnosti gdje se definira razina vjerojatnosti u rasponu od 0 do 1.
- Učenje: u dosadašnjim opisanim pristupima "inteligencija" agenata je kreirana od strane dizajnera. U području gdje je znanje nesigurno ili gdje je okolina u kojoj se agent nalazi vrlo varijabilna, učenje može biti jedini način da sazna potrebno znanje za rješavanje problema. Algoritmi koji se u ovoj domeni najčešće primjenjuju su algoritmi iz područja strojnog učenja te neuronskih mreža. Također, pristup učenju može biti nasumično pretraživanje te kada postoji odgovarajuća povratna informacija o uspješnosti, tada je moguće odrediti koji su potezi bili dobri a koji ne.
- Komunikacija, percepcija, djelovanje: kroz algoritme procesiranja prirodnog jezika pokušava se omogućiti da inteligentni agent može razumjeti prirodni govor čovjeka te se pokušava omogućiti da može komunicirati prirodnim jezikom čovjeka. Također se, kroz primjenu raznih ulaznih senzora (kamera, mikrofona, taktilni senzori i sl.) pokušava inteligentne agente osposobiti da mogu zaključivati o raznim aspektima iz stvarnog svijeta te da na kraju mogu i djelovati u skladu s dobivenim informacijama. Područje robotike se bavi ovim područjem. Neki poznati problemi iz ove domene su prepoznavanje govora, prepoznavanje mimika lica i prepoznavanje predmeta.

Kako bi se kreirao adaptabilni sustav poučavanja sviranja seta bubnjeva, u radu se primjenjuju određeni koncepti iz područja umjetne inteligencije. Postoji više mogućih pristupa kreiranja ovakvog inteligentnog sustava. Centralni problem sustava je korisnika naučiti što bolje svirati set bubnjeva u što kraćem vremenskom roku. Kako bi računalni sustav mogao simulirati proces poučavanja, implementirani su algoritmi koji vrše funkcije nastavnika: slušanje što korisnik svira, analiza odsviranih nota te davanje uputa za otklanjanje učinjenih grešaka te usmjeravanje korisnika u daljnjem usvajanju znanja i vještini sviranja. Znanje koje korisnik treba usvojiti su ritmički uzorci. S obzirom da se oni mogu unaprijed definirati, moguće je stvoriti bazu znanja koja će služiti kao osnova za vođenje korisnika kroz nastavni sadržaj. Sadržaj se treba prilagođavati potrebama korisnika u skladu s njegovim mogućnostima.

2.2.2.1. Ekspertni sustavi

Ekspertni sustavi su računalni programi koji ulaze u primijenjeno područje umjetne inteligencije. Osnovna ideja iza ekspertnih sustava je da takvi sustavi sadrže znanje eksperta nekog područja. Tom znanju korisnik sustava tada može pristupiti i koristiti ga kako bi dobio savjet, odgovor na specifično pitanje i sl. Računalo na temelju ulaznih podataka vrši proces zaključivanja te dolazi do određenog zaključka. Nakon procesa zaključivanja korisniku daje odgovor i/ili objašnjenje zašto i kako je došao do odabranog odgovora (Lucas & Gaag, 1991). Slika 2.3. prikazuje globalnu arhitekturu ekspertnih sustava.



Slika 2.3. Globalna arhitektura ekspertnih sustava

Postoji 11 temeljnih metodologija izrade ekspertnih sustava (Liao, 2005):

1. Sustavi temeljeni na pravilima - ovakvi sustavi sadrže znanje eksperta koje se nalazi u obliku niza AKO-TADA pravila. Na temelju definiranih pravila, vrši se proces zaključivanja nad ulaznim podacima. Ovim pristupom se mogu razviti i sustavi poučavanja (Hatzilygeroudis & Prentzas, 2004; Chan et al., 1995).
2. Sustavi temeljeni na znanju - ova vrsta sustava se direktno veže na koncepte umjetne inteligencije te ovakvi sustavi pokušavaju imitirati ljudsko znanje i ljudsko zaključivanje. Ova metodologija je najzastupljenija te predstavlja klasičan primjer generalne arhitekture ekspertnih sustava. Ovaj pristup je također zastupljen u kreiranju sustava za učenje i prikaz znanja (Mockler et al., 2000; Mitra & Basu, 1997).
3. Sustavi temeljeni na neuronskim mrežama - umjetna neuronska mreža je model prema kojem se emulira rad biološke neuronske mreže. Ovaj koncept se koristi kako bi se implementirale računalne simulacije velike količine paralelnih procesa koji su

međusobno isprepleteni mrežnom arhitekturom. I ovim pristupom je moguće razviti sustave za učenje (Stathacopoulou et al., 1999).

4. Sustavi temeljeni na neizrazitoj (eng. fuzzy) logici - ovakvi sustavi se bave s nesigurnošću u odlučivanju. S obzirom da se kod odlučivanja stvari ne mogu najčešće prikazati kao točno ili netočno, crno ili bijelo, već postoje i zaključci tipa "moglo bi biti". Neizrazita logika simulira normalno promišljanje čovjeka koje nije uvijek tako precizno i logično kao kod standardnih računalnih algoritama. Ovakva metodologija se može koristiti u razvoju sustava za poučavanje (Warendorf & Tsao, 1997).
5. Sustavi objektno orijentirane metodologije - ovakav pristup objedinjuje u jedan objekt podatke zajedno sa specifičnim procedurama nad podacima. U objektu sadržani su podaci i programski kod. U ovakvom pristupu dohvaćanjem objekata se automatski vrše i procedure vezane uz taj objekt. Slanjem iste poruke različitim objektima izvršavaju se i različite procedure. Ovakva arhitektura ima modularan pristup stoga je vrlo pogodna za ponovno korištenje kreiranih objekata. Ovim pristupom se također mogu razviti sustavi za učenje i prikaz znanja (Menzis, 1997; Vranes & Stanojevic, 1995).
6. Sustavi zaključivanja na temelju slučaja - Ovakav pristup se temelji na ideji da postoji baza riješenih problema (slučajeva) te da se na temelju tih rješenja mogu riješiti novi slučajevi. Kada se pojavi novi problem sličnih parametara, baza slučajeva traži najbliži slučaj te primjenjuje rješenje tog slučaja na novi problem. Postoje primjeri gdje se ovakav pristup koristi u učenju putem Interneta i modeliranju znanja (Fu & Shen, 2004; Gardan & Gardan, 2003).
7. Modeliranje - modeliranje je postala interdisciplinarna metodologija ekspertnih sustava koja pokušava izgraditi formalne odnose s dizajnom logičkih modela za različite problemske domene. Tehnike modeliranja koriste kvantitativne metode kako bi se izvršila analiza podataka te kako bi se prikazalo i prikupilo znanje (korištenjem induktivne logike ili raznih algoritama). Kreiranjem alata za modeliranje stvaraju se platforme koje se koriste u području umjetne inteligencije, kognitivne znanosti i dr.
8. Sistemska arhitektura - ova arhitektura se temelji na kreiranju općeg modela, nacрта. Arhitektura prikazuje osnovne mogućnosti, sučelja, funkcije, tok podataka, upravljanje sustavom, protokole i sl. Nakon osnovnog dizajna i implementacije, korisnici mogu manipulirati i kontrolirati funkcije arhitekture sustava.
9. Inteligentni agenti - kreiranje autonomnih agenata koji putem svojim senzora analiziraju okolinu te djeluju u skladu s prikupljenim podacima. Inteligentni agenti

mogu biti vrlo jednostavni a i vrlo složeni: mogu jednostavno vršiti unaprijed definirane funkcije ili učiti i modificirati svoje znanje u skladu s ciljevima. I u kreiranju sustava poučavanja moguće je koristiti princip kreiranja inteligentnih agenata (Cruces & De Arriaga, 2000).

10. Ontologija - ontologija je sustav imenovanja i definiranja tipova, svojstava i veza koji se koristi kao fundamentalni koncept kako bi se opisalo znanje određene domene. Ontologije mogu biti osnova za ostvarivanje komunikacije čovjeka sa sustavom kao i komunikaciju među sustavima. Ovakav pristup pogodan je za modeliranje znanja kao i akviziciju znanja (Gardan & Gardan, 2003; Ruiz-Sanchez et al., 2003).
11. Sustavi temeljeni na bazi podataka - ekspertni sustavi koji se temelje na velikim količinama podataka mogu efikasno funkcionirati kreiranjem baza podataka. Kod velike količine podataka, potrebno je posebnu pažnju usmjeriti na algoritme pretraživanja baze.

Iz navedenog se vidi da postoje brojni pristupi u kreiranju ekspertnih sustava. Ekspertni sustavi poučavanja mogu se kreirati različitim metodologijama. Također valja primijetiti da postoji i dosta preklapanja u različitim metodologijama što se tiče domena primjene. Mnogi ekspertni sustavi nisu striktno vezani uz pojedinu metodologiju već je moguće i za pojedine dijelove sustava koristiti određeni pristup, već prema procjeni eksperata i dizajnera sustava.

2.2.2.2. Računalom potpomognuto poučavanje i inteligentni sustavi poučavanja

Kao posebna kategorija među računalnim programima koji koriste koncepte umjetne inteligencije nalaze se i računalni programi koji služe u svrhu poučavanja. Ovi programi mogu se svrstati u dvije osnovne kategorije (Polson & Richardson, 2013):

- Računalom potpomognuto poučavanje (Computer Assisted Instruction),
- Inteligentni sustavi poučavanja (Intelligent Tutoring System).

U najširem smislu, svaki računalni program koji služi u edukativne svrhe ulazi u kategoriju računalom potpomognutog poučavanja. Postoji mnogo različitih termina koji označavaju ovu kategoriju računalnih programa. U tablici 2.2. prikazani su najčešći pojmovi koji se vežu uz ovaj tip računalnih programa (Ward, 2007).

Tablica 2.2. Računalom potpomognuto poučavanje (CAI, 2008; Ward, 2007)

Kratice	Značenje
CAI	Computer Aided Instruction
CAI	Computer Assisted Instruction
CAL	Computer Assisted Learning
CBE	Computer Based Education
CBI	Computer Based Instruction
CBT	Computer Based Training
CEI	Computer Enriched Instruction
CMI	Computer Managed Instruction
WBI	Web Based Instruction
WBL	Web Based Learning
WBT	Web Based Training

Kratice CBE te CBI se koriste kao termini koji najšire obuhvaćaju sve računalne programe koji imaju edukacijsku svrhu. CAI je pojam koji se odnosi na malo uže područje a najčešće se odnosi na dva osnovna tipa ovakvih sustava: tutori te alati (Levy, 1997). Tutori se sastoje od nastavnog sadržaja koji se prezentira na određeni način dok CAI programi kao alati služe primarno kao sredstvo unapređenja procesa učenja i najčešće su fokusirani na određeni zadatak (CAI, 2008). Novija terminologija uključuje i web programe koji se koriste putem Interneta.

CAI programi se najčešće sastoje od nastavnog sadržaja koji se prezentira korisniku putem računala. Sadržaj može biti u tekstualnom ili nekom drugom multimedijском obliku. Prednosti ovakvog pristupa su brojne: interakcija tipa jedan na jedan, neposredna povratna informacija na pitanja, mogućnost prolaska nastavnog sadržaja brzinom koja odgovara korisniku. Glavni nedostaci su skupi razvoj, održavanje i nadogradnja kao i strah da će računala u procesu edukacije smanjiti količinu ljudske interakcije (CAI, 2014).

Određene prednosti i nedostaci su ponekad isprepleteni: prednost je često da korisnik u manje vremena može naučiti više no ponekad korisnika može smetati velika količina sadržaja. Ili primjerice, multimedijски sadržaj može pomoći kako bi se usvojili određeni teži koncepti no ponekad multimedijски sadržaj može odvratiti pažnju od bitnih stvari. Nepostojanje kvalitetnih CAI rješenja je definitivno jedan od glavnih nedostataka (CAI, 2008).

Postoji nekoliko osnovnih pristupa koji se koriste prilikom razvoja CAI programa:

- Ponavljanje i vježbanje. Kod ovog pristupa korisniku se objašnjava neka vježba ili vještina te nakon toga korisnik vježba ponavljajući naučenu vještinu. Ovaj pristup je pogodan za vježbanje mehaničkih radnji i vještina kod kojih je kognitivni teret na nižoj razini.
- Tutorski pristup. Ovo je najčešće korišten pristup kod razvoja CAI programa koji oponaša klasični školski pristup: korisniku se prezentiraju informacije te ga se usmjerava kroz različiti nastavni sadržaj dok korisnik rješava zadatke i odgovara na pitanja vezana uz nastavni sadržaj.
- Simulacija. Ovaj pristup se koristi u slučajevima gdje je nemoguće neko znanje ili vještinu vježbati u stvarnom svijetu, primjerice upravljanje avionom. Zbog ekonomskih razloga u ovom primjeru, koristi se simulator koji pomaže korisniku savladati određenu vještinu prije nego što dođe u stvarnu situaciju gdje je mora i primijeniti.
- Igre. U ovakvim programima najčešće postoji određena natjecateljska komponenta (vremensko ograničenje, utrka, bodovna ljestvica, bedževi). S obzorom da pristup ima natjecateljske komponente, ovakvi programi često vrlo pozitivno utječu na motivaciju korisnika (Ward, 2007).

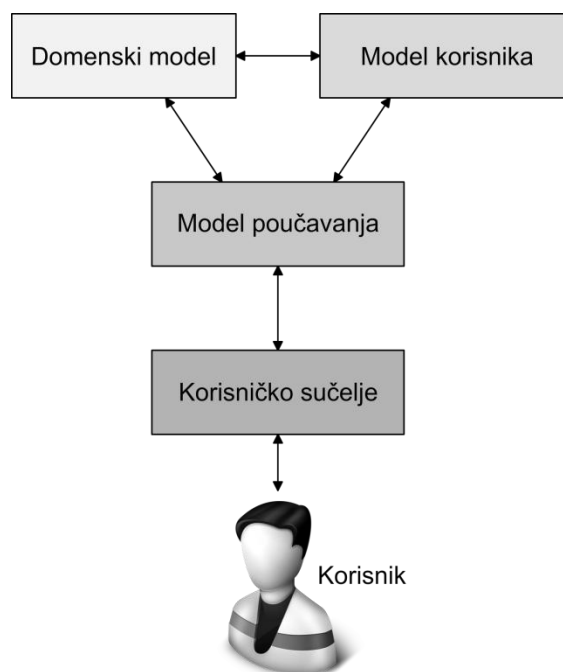
Što se tiče efikasnosti korištenja CAI programa u edukaciji, možemo vidjeti da postoje pozitivni rezultati. Na temelju analize 42 studije gdje se mjerila efikasnosti učenja pomoću CAI programa u odnosu na tradicionalno učenje u području znanstvene edukacije, CAI polaznici su u pravilu bili uspješniji (Bayraktar, 2001). Druga studija sumirala je 52 istraživanja koja su provedena u Tajvanu te je zaključak bio da je CAI pristup efikasniji od tradicionalnog pristupa (Liao, 2007). Interaktivne simulacije i koncepti računalnih igara su se također pokazali uspješni u procesu učenja. To je potvrdila i studija koja je sumirala 32 istraživanja koja su primjenjivale ovakve pristupe u CAI programima u procesu učenja (Vogel, 2006). Također je zabilježena značajnija efikasnost prilikom korištenja WBI programa kod učenja deklarativnog znanja u slučajevima gdje su učenici imali mogućnost kontroliranja nastavnog sadržaja (Sitzmann et al., 2006).

Za razliku od CAI sustava, inteligentni sustavi poučavanja (ISP) koriste koncepte iz područja umjetne inteligencije te na taj način određene funkcionalnosti djeluju "inteligentno". Kako bi

se neki računalni sustav mogao nazvati ISP-om, potrebno je zadovoljiti tri temeljna kriterija (Polson, 2013):

1. Ekspertno znanje - u sustav mora na neki način biti uključeno ekspertno znanje iz odgovarajućeg područja te se na temelju tog znanja kreiraju razna sučelja putem kojih korisnik vrši interakciju i rješava zadatke i probleme.
2. Procjena znanja - sustav treba imati sliku o tome koje znanje je korisnik usvojio. Sustav mora bilježiti aktivnosti korisnika te na temelju njegovih aktivnosti bilježiti njegov napredak u znanju.
3. Strategija poučavanja - sustav mora biti u mogućnosti usmjeravati korisnika kroz bazu znanja. S obzirom na naučene komponente, sustav odabire sljedeće lekcije koje su primjerene za korisnika na temelju procijenjenog znanja.

Inteligentni sustavi poučavanja se standardno sastoje od sljedeće 4 komponente (Stankov et al., 2010):



Slika 2.4. Globalna arhitektura inteligentnih sustava poučavanja

Domenski model (također se koriste nazivi kognitivni model te model ekspertnog znanja) sastoji se od koncepata, pravila i strategija za rješavanje problema u kontekstu domene u kojoj korisnik uči. To su mehanizmi zaključivanja koji evaluiraju korisnika i njegovu interakciju sa sustavom, detektiraju greške i sl. Ovisno o tome kako je ISP građen i temelji li se na bazi

znanja, ovaj model može imati i dodatnu ulogu: može biti izvor ne samo mehanizama zaključivanja već i ekspertnog znanja koje je ugrađeno u sustav (Nkambou et al., 2010).

Model korisnika služi tome kako bi se pratilo što je korisnik prilikom korištenja sustava naučio. Ovdje se pohranjuju podatci o njegovom napretku. Ovisno o domeni primjene ISP-a te o mehanizmima zaključivanja u sustavu, u modelu korisnika se zapisuju različiti podatci o korisniku kako bi se mogla vršiti dedukcija i usmjeravanje kretanja korisnika kroz sustav.

Model poučavanja služi usmjeravanju korisnika kroz sustav, zadatke, bazu znanja i sl. Na temelju baze znanja i na temelju studentskog modela, odabire se strategija poučavanja i daljnje akcije koje su primjerene korisniku sustava da na najbolji mogući način nastavi svoje učenje. Također, ponekad je korisniku dobro omogućiti i da sam bira što učiti dalje ili omogućiti korisniku dobivanje dodatne pomoći ako ima problema sa određenim dijelom nastavnog sadržaja. Ovdje se definiraju moguće strategije koje se koriste u procesu učenja.

Korisničko sučelje je vidljivi dio sustava putem kojeg korisnik vrši interakciju sa sustavom. Korisniku se putem korisničkog sučelja omogućava navigacija kroz sustav kao i učenje pojedinih nastavnih cjelina. Također putem korisničkog sučelja korisnik dobiva povratnu informaciju o svom napredovanju. Korisničko sučelje može se sastojati od multimedijskog sadržaja u najrazličitijim formama, od običnog teksta, audio sadržaja, video sadržaja, interaktivnih animacija i sl.

Razvoj ISP-ova je vrlo sličan procesu instrukcijskog dizajna te se sastoji od četiri iterativne faze: definiranje potreba, analiza kognitivnih zadataka, inicijalna implementacija tutora te evaluacija (Corbett et al., 1997). Proces definiranja potreba se provodi tako da se vrši konzultiranje s ekspertom iz domene za koju se želi razviti ISP. Potrebno je definirati znanje koje se pokušava prenijeti kao i mehanizmi zaključivanja. Jednom kada su poznati parametri koje je potrebno mjeriti, kreira se studentski model. U drugoj fazi kognitivni zadatci se pokušavaju operacionalizirati. Najčešće se to radi kroz intervju s ekspertom. U trećoj fazi se vrši implementacija sustava kako bi se mogla izvršiti faza evaluacije koja će pokazati da li je sve implementirano u skladu sa zadanim parametrima. Ekspert je u pravilu uključen u svim fazama izrade sustava.

Efikasnost ovih sustava će se raspraviti prilikom analize pojedinih računalnih sustava koji su razvijeni u domeni glazbenog stvaralaštva i edukacije sviranja glazbenih instrumenata.

2.2.2.3. Adaptabilni sustavi poučavanja


Često se adaptabilni sustavi poučavanja (ASP) poistovjećuju s inteligentnim sustavima poučavanja. Ako se pogleda generalna arhitektura ovih računalnih sustava, vidjet ćemo da je ona identična. Često se koristi drugačija terminologija, no u suštini radi se o istim modelima.

Tablica 2.3. Usporedba terminologije ASP-a i ISP-a

Inteligentni sustav poučavanja	Adaptabilni sustav poučavanja
Domenski model	Ekspertni model
Model korisnika	Studentski model
Model poučavanja	Instrukcijski model
Korisničko sučelje	Instrukcijska okolina

Iz tablice možemo vidjeti da se ovi sustavi sastoje od istih modela samo se službeno koristi nešto drugačija terminologija. Koriste se i drugi sinonimni nazivi za ove modele no u principu predstavljaju istu stvar.

No funkcionalno gledano, adaptabilni sustavi poučavanja nisu sinonim za inteligentne sustave poučavanja. Adaptabilni sustavi se prilagođavaju karakteristikama korisnika prema prikupljenim informacijama u modelu korisnika, tj. studentskom modelu. Inteligentni sustavi primjenjuju tehnike iz područja umjetne inteligencije kako bi sustav dao bolju povratnu informaciju i omogućio kvalitetniji proces učenja. Tako neki sustavi mogu biti inteligentni a da nisu adaptabilni: uvijek će dati istu dijagnozu za neki problem, bez obzira na prijašnje iskustvo korisnika, uvijek će dati istu vježbu za otklanjanje iste greške. Jednako tako, sustav može biti adaptabilan a ne nužno inteligentan: nastavni sadržaj se prilagođava korisniku na temelju točnog ili netočnog odgovora korisnika no ne koriste se nikakvi složeniji mehanizmi u evaluaciji korisnika. Na posljetku, sustavi mogu biti i adaptabilni i inteligentni tako da se primjenjuju i jedni i drugi koncepti (Phobun & Vicheanpanya, 2010; Brusilovsky, 1999). Slika 2.5. prikazuje odnos između inteligentnih i adaptabilnih sustava poučavanja.



Slika 2.5. Odnos između inteligentnih i adaptabilnih sustava poučavanja (Brusilovsky & Peylo, 2003)

Dva osnovna koncepta koja su osnova karakteristike adaptabilnosti su: adaptabilna prezentacija sadržaja te adaptabilna navigacija. Ciklus adaptabilnosti se izvodi u četiri koraka: dohvaćanja informacija od korisnika, analiziranja tih informacija, odabira sljedeće lekcije te prezentiranja lekcije korisniku (Shute & Zapata-Rivera, 2012). Osnovni koncepti karakteristike inteligencije su: dinamički odabir lekcija, inteligentna analiza rješenja, potpora za rješavanje problema. Razlog zašto se ovi pojmovi miješaju je zato što ne postoji vrlo jasna granica kada neko svojstvo ulazi u područje adaptabilnosti a kada u područje inteligencije. Primjerice, ukoliko se radi o analizi odgovora po principu točno/netočno, onda je to adaptabilnost. No ako se vrši složenija analiza odgovora te ako je moguće preciznije odrediti što je problem, tada to ulazi u domenu inteligencije. No pitanje je koja je to razina složenosti analize odgovora kod koje prestaje adaptabilnost a počinje inteligencija. Granicu je u određenim slučajevima vrlo teško odrediti stoga je ponekad i teško odrediti u kojoj mjeri je neki sustav adaptabilan a u kojoj inteligentan.

2.3. Računalni programi u glazbenoj edukaciji

Tržište računalnih aplikacija sve je bogatije raznim aplikacijama u mnogim domenama. Na dnevnoj bazi, razvijaju se stotine aplikacija u različitim područjima interesa. U nastavku će biti spomenuti alati koji su opisani u znanstvenoj literaturi a koji se nalaze u domeni glazbene edukacije. Prema Percivalu, postoje tri glavna područja od interesa za razvojem računalnih sustava u glazbenoj edukaciji (Percival, 2007):

- poboljšanje rada profesora sa studentima,
- motivacija studenta na rad, i
- poboljšanje individualnog rada studenata.

Većina alata obično pokušava ostvariti dva od ova tri cilja: motivacija, te jedno od preostalih područja. No može se ostvarivati i samo jedan cilj. Računala zasigurno još dugo neće moći konkurirati profesorima, posebice u umjetničkom području kao što je glazba. Sve dok ne budu postojala računala koja će moći ne samo evaluirati odsvirane note već će imati i senzore koji će moći kvalitetno evaluirati i držanje tijela, tehniku sviranja, procijeniti emocionalno stanje učenika, računala neće moći zamijeniti rad profesora (Percival, 2007).

Motivacija je također jako važan faktor kod određene grupacije korisnika. Nekim učenicima je potrebna samo motivacija kako bi pokazali bolje rezultate. Računala zasigurno mogu pomoći u tom području (Finney & Burnard, 2010; Ferrari et al., 2006; Pitts & Kwami, 2002). Korištenjem najrazličitijeg multimedijskog sadržaja moguće je uvelike motivirati korisnike na rad. No treba biti oprezan. Korisnici koji su motivirani ne trebaju sav taj sadržaj te im on može čak biti i teret. Koncepti računalnih igara su se također pokazali vrlo uspješni u motiviranju učenika, jer učenici imaju dojam da uče kroz zabavu (Koster, 2013; Klimmt, 2003).

Dva izuma koja su pomogla u samostalnom učenju sviranja su metronom i viljuška za štimanje. Uz današnju tehnologiju, moguće je mnogo više. Učenici imaju ograničeni broj sati s profesorom tjedno te ne mogu tijekom vježbanja dobiti povratnu informaciju rade li nešto dobro ili krivo. Računala mogu pomoći učenicima na način da im mogu omogućiti dobivanje neposredne povratne informacije o sviranju i napretku. Također, vježbanje može biti snimano, analizirano od strane računala ili čak kasnije od strane profesora.

Što se tiče vrste nastavnog sadržaja kojom se računalni sustav može baviti, istaknuta je sljedeća klasifikacija (Brandao et al., 1999):

- učenje temeljnog glazbenog znanja,
- učenje vještina sviranja glazbenog instrumenta,
- glazbena analiza, te
- glazbena kompozicija.

Najveći broj računalnih sustava u ovoj domeni ulazi u prvu kategoriju s obzirom na to da je ona temeljna kategorija znanja na kojoj se sve ostalo gradi. Ova kategorija je zanimljiva jer pokriva neka osnovna znanja koja su općenita i potrebna za sviranje bilo kojeg instrumenta.

Alati koji se nalaze u ovoj kategoriji su najčešće alati putem kojih se uči glazbena notacija, rade se slušni testovi putem kojih je potrebno prepoznati određeni melodijski i ritmički uzorak, glazbeni interval, melodijsku progresiju, akorde te harmonizaciju.

Istraživanja su pokazala da usvajanje znanja i vještina ove kategorije potpomognuto računalnom tehnologijom predstavlja manje stresno okruženje u odnosu na grupne vježbe i tradicionalan način poučavanja (Brandao et al., 1999). Učenici su bili slobodniji raditi uz računalo nego kada su ih okruživali drugi učenici ili dok su bili pod stalnim nadzorom profesora. Također s obzirom na popularnost Interneta i učenja preko Interneta, postoje određena istraživanja gdje su se pokušale napraviti virtualne okoline gdje bi učenici putem računala kooperativno učili glazbeni sadržaj (Fernada et al., 2004). Pametni telefoni danas također predstavljaju sredstvo koje je svima dostupno te postoje pokušaji da se stvore kolaborativne okoline za učenje glazbenog sadržaja putem ove tehnologije (Yinsheng, 2013).

Sustavi koji se bave učenjem vještina sviranja glazbenih instrumenata su izravno vezani uz temu ovog rada te su stoga i najzanimljiviji predstavnici računalnih sustava. U nastavku će biti dan opis tih sustava, njihova svojstva i karakteristika. Identificirani su pozitivni aspekti u pristupu učenja sviranja glazbenih instrumenata koji predstavljaju podlogu razvoja novog poboljšanog konceptualnog modela na temelju kojeg je razvijen prototip radi testiranja uspješnosti novokreiranog modela kroz evaluacijski proces.

Treća i četvrta kategorija računalnih sustava nisu izravno vezani uz temu ovog rada iako će ukratko biti spomenuti i računalni programi koji se djelomično bave i ovom vrstom nastavnog sadržaja. Prvo će biti opisani programi koji ulaze u prvu kategoriju, učenje temeljnog glazbenog znanja. Nakon toga slijedi opis računalnih sustava koji ulaze u drugu kategoriju, učenje sviranja glazbenih instrumenata. Nakon toga će biti opisani i neki komercijalni proizvodi koji se nalaze u ovoj domeni a nema ih u znanstvenoj literaturi no bave se izravno tematikom ovog rada. Na kraju, spomenut će se i nekoliko proizvoda iz područja računalnih igara koji, osim što su igre, imaju i edukacijsku svrhu i primjenu. Određene igre imaju mehaniku koja podsjeća na sviranje pravog glazbenog instrumenta dok postoje i računalne igre kod kojih se koriste pravi instrumenti za njihovo igranje.

2.3.1. Računalni sustavi učenja temeljnog glazbenog znanja

U nastavku slijedi opis nekoliko najznačajnijih predstavnika računalnih programa koji se koriste u domeni učenja temeljnog glazbenog znanja.

2.3.1.1. Continuator

Continuator (Ferrari, 2006) je računalni sustav koji je kreiran sa svrhom da zainteresira djecu predškolske dobi za glazbu. Želja je bila kreirati sustav koji bi se mogao koristiti u svakodnevnim školskim aktivnostima. Sustav funkcionira tako da proizvodi glazbu istog ili sličnog stila, poput korisnika koji svira sintesajzer. Nakon što korisnik odsvira nekoliko nota, sustav svira nekoliko nota natrag korisniku, poput dijaloga. "Odgovor" sustava se temelji na ulaznim notama koje je odsvirao korisnik, ponavlja ih i mijenja ulazne note te svira sličnu glazbenu frazu. Na taj način se sustav prilagođava korisniku i njegovom "stilu" sviranja, kao i samoj sposobnosti sviranja.

Rezultati istraživanja su pokazali kako je ovaj sustav uspješno kreirao interaktivnu okolinu između djece i računalnog sustava. Na temelju teorije protoka (Csikszentmihalyi, 1997), utvrđeno je da je potaknuto stanje kreativnosti kod djece, kao i osjećaj zadovoljstva korištenjem kreiranog sustava. Interakcija djece sa sustavom rezultirala je povećanom vremenu pažnje i koncentracije kod djece. Također, interakcija potiče razvoj vlastite intrinzične motivacije. Djeca su također pokazala veliki interes za istraživanje glazbenog sadržaja (Pachet, 2004).


Provedeno je dodatno istraživanje kroz različite kreirane igre. U jednoj igri djeca su zamislila da su određena životinja te su trebali smisliti melodiju koja bi predstavljala "zov" te zamišljene životinje. Nakon što bi odsvirali glazbenu frazu, Continuator ju je ponovio ili malo izmijenio. Za to vrijeme djeca su trebala plesanjem i micanjem tijela trebala oponašati zamišljenu životinju. Druga kreirana igra igrala se tako da je jedno dijete odsviralo neku glazbenu frazu a nakon toga bi slijedilo ponavljanje od strane Continuatora. Za to vrijeme, djeca su plesala oko stolica te u trenutku kada je Continuator prestao svirati, djeca su trebala sjesti.

Istraživanje je pokazalo da je sustav također bio pogodan za kolaboraciju. Djeca bi zajedno surađivala i svirala različite glazbene uzorke te bi se dogovarali što i kako će svirati (Ferrari, 2006).

2.3.1.2. Hyperscore

Hyperscore (Farbood, 2001) je inteligentni računalni sustav koji omogućava početnicima, posebice djeci, da stvaraju glazbu bez prethodne glazbene izobrazbe. To je realizirano tako da se ne koristi standardna glazbena notacija već korisnici crtanjem linija kreiraju glazbene motive te ih zatim kombiniraju u veće cjeline. Kroz ovaj sustav korisnici mogu naučiti osnovne glazbene karakteristike glazbenih uradaka (visina note, ritam, osnovna harmonija, struktura pjesme i sl.). Ti koncepti se usvajaju kroz proces kreiranja glazbe stoga ovaj sustav ulazi djelomično i u kategoriju sustava koji uče glazbenu kompoziciju.

Samo sučelje se sastoji od dva tipa prozora: prozor za kreiranje "motiva" te prozor za "skiciranje". U prozoru za kreiranje motiva korisnici iscrtavanjem linija u prostoru kreiraju kratke glazbene motive. Y os određuje visinu tona dok pozicija na x osi vrijeme kada nota treba biti odsvirana i njeno trajanje. Sam proces skladanja polazi od pretpostavke da se glazbeno djelo sastoji od niza motiva stoga nakon što se definiraju motivi, svakom motivu se dodjeljuje jedna boja. Crtanjem linija određene boje u prozoru za skiciranje, stvara se konačna kompozicija koja se sastoji od pojedinačno kreiranih motiva. Ako je iscrtana linija duža po trajanju od kreiranog motiva, tada se motiv ponavlja. Osim što se ubacuju kreirani motivi, moguće je kreirati neovisne linije na temelju kojih sustav generira melodiju, na temelju oblika same linije. Također je moguće generiranje harmonijskih dijelova mijenjanjem središnje linije u prozoru za skiciranje (Farbood et al., 2004).

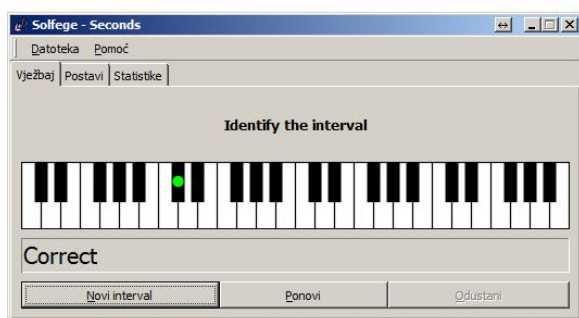


Slika 2.6. Hyperscore grafičko sučelje: motivi i prozor za skiciranje

Provedena je studija slučaja koja je pokazala kako djeca u pravilu prolaze kroz nekoliko tipičnih faza u radu sa sustavom. Na početku se upoznaju sa sučeljem te su prvi motivi koje kreiraju vrlo nepovezani, kako ritmički, tako i melodijski. Već kod drugog i trećeg susreta sa sustavom, djeca su počela stvarati uzorke koji su imali neku konkretniju formu. Iako su sustav koristili samostalno, u studiji slučaja sudjelovala je i profesorica koja ih je navodila u njihovom glazbenom stvaranju. Nakon 5 faza korištenja sustava, djeca su uspješno napravila svoje prve skladbe kombinirajući kreirane motive u prozoru za skiciranje te dodatnim iscertavanjem linija kreirati razne melodijske varijacije (Jennings, 2005). Sustav na temelju kreiranih linija stvara MIDI zapis koji se reproducira putem MIDI sučelja na računalu.

2.3.1.3. GNU Solfège

GNU Solfège (GNU Solfège, 2004) je besplatna aplikacija koja je zamišljena kao alat za treniranje slušnog prepoznavanja raznih glazbenih intervala, ritmova, akorda, ljestvica i drugih glazbenih sadržaja. Lekcije unutar kategorije su poredane po težini. Primjerice, ako se odabere treniranje intervala, potrebno je odabrati koji raspon intervala korisnik želi vježbati: prva lekcija je vježbanje sekunda, nakon toga se dodaju terce, kvarte, kvinte itd. Korisniku se u grafičkom sučelju prikazuju tipke klavira te mu se vizualno prikazuje prva odsvirana nota. Nakon toga aplikacija svira drugu notu a korisnik mora prepoznati o kojem se intervalu radi te klikom miša na grafičkom prikazu klavira odabire notu za koju smatra da je odsvirana. Sustav daje povratnu informaciju o tome je li odgovor točan ili ne. Sustav također vodi statistiku o uspješnosti korisnika te korisnik može vidjeti svoj napredak, ovisno o vrsti vježbe. Statistika se vodi u nekoliko vremenskih intervala: za trenutnu aktivnost, današnji dan, tjedan dana ili od početka korištenja aplikacije. Slika 2.7. prikazuje sučelje za prepoznavanje intervala te statističke podatke koji se prate o korisniku za određenu vježbu.



a)

	Session		Today		Last 7 days		Total	
	Percent	Count	Percent	Count	Percent	Count	Percent	Count
Total	67%	6	67%	6	67%	6	67%	6
m2 ↑	100%	3	100%	3	100%	3	100%	3
M2 ↑	33%	3	33%	3	33%	3	33%	3


b)

Slika 2.7. a) Grafičko sučelje za rad s intervalima b) Statistički podatci o vježbi

Kod složenijih vježbi, korisniku je omogućena i opcija "Odustani" nakon koje aplikacija prikazuje točan odgovor. Za svaku vježbu, svaki put se generiraju drugačije vježbe osim za neke specifične vježbe koje su unaprijed u potpunosti predefinirane. Alat je vrlo jednostavan no ispunjava svoju svrhu i može poslužiti kao vrlo praktično pomagalo u učenju osnovnih glazbenih vještina.

2.3.1.4. Auralia 4

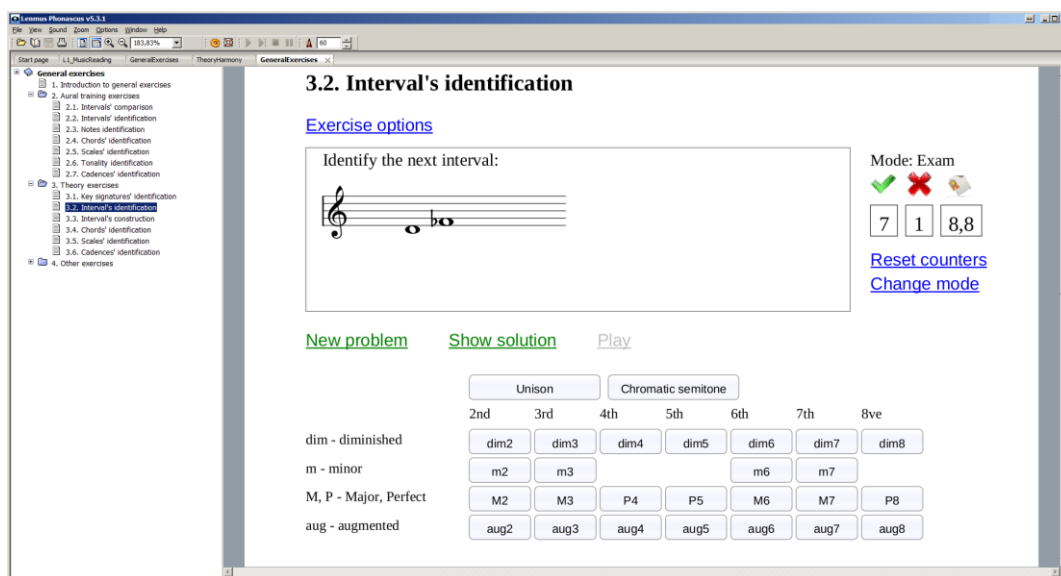
Auralia 4 (Auralia 4, 2015) je komercijalni računalni sustav iste namjene kao i GNU Sofege. Lekcije u ovom sustavu su razvrstane u 5 kategorija: intervali i ljestvice, akordi, ritam, harmonija i forma, visina tona i melodija. Ukupno ima 41 lekciju. Osim vježbi za praktično vježbanje navedenih elemenata, također sadrži i teoretsko znanje. Svaka lekcija se može u potpunosti prilagoditi po svom sadržaju potrebama korisnika: za svaku lekciju možete točno definirati koji segment svake lekcije želite vježbati. Također, osim standardnog grafičkog prikaza klavira, moguće je koristiti i prikaz vrata gitare kao i solomizacijski prikaz. Sustav također ima podršku za korištenje u nastavi te putem sustava možete pratiti rezultate svakog učenika. Moguće je kreirati svoj nastavni plan i program ili odabrati neki od unaprijed definiranih programa. Zvuk se u sustavu reproducira putem MIDI sučelja. Prednost ovog sustava je što ima ugrađen algoritam za detekciju visine tona s audio ulaza stoga je sustav moguće koristiti i kao alat za vježbanje pjevanja s obzirom da se odgovori na lekcije mogu dati u glasovnom obliku.



Slika 2.8. Auralia 4: Vježba prepoznavanja intervala

2.3.1.5. LenMus

LenMus (LenMus, 2015) je edukacijski softver u obliku interaktivne knjige. Sastoji se od četiri glavna poglavlja: a) općenite vježbe, b) glazbena pismenost prve razine, c) glazbena pismenost druge razine te d) teorija i harmonija. U sekciji općenitih vježbi nalaze se vježbe slušanja i prepoznavanja intervala, nota, akorda, tonaliteta i drugih glazbenih elemenata, poput računalnih sustava kao što je već opisano. Osim već navedenih klasičnih vježbi, uključene su i teoretske vježbe poput prepoznavanje tonaliteta, konstrukcija intervala i akorda i osnovno čitanje nota u zadanom intervalu. Vježbe se sastoje od interaktivnog sučelja putem kojeg korisnik daje odgovore na generirane zadatke. Zanimljiva vježba je vježba čitanja nota gdje se odabire interval raspona nota te sustav tada kreira svaki puta drugačiji niz od 8 taktova nota, no vrlo brzo se mogu uočiti uzorci na temelju kojih se zadatci generiraju. LenMus podjednaku važnost daje teoriji kao i praktičnim zadacima stoga je izuzetno pogodan kao pomoćni edukacijski alat za glazbene škole.



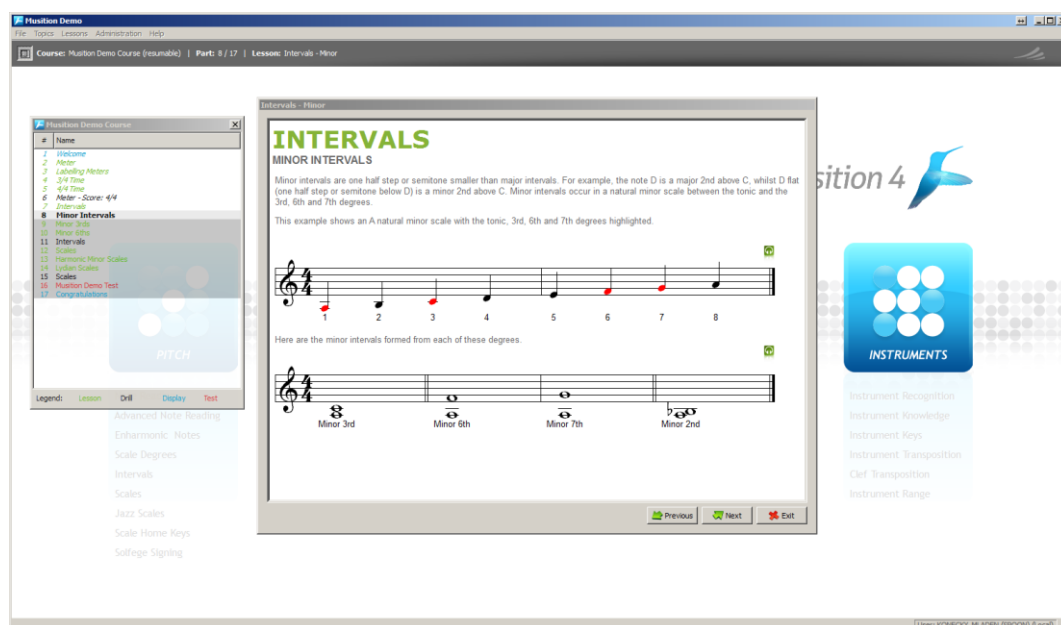
Slika 2.9. LenMus sučelje: Ispitni način rada vježbe prepoznavanja intervala

Vježbe u LenMus-u se mogu izvoditi u nekoliko načina rada: učenje, vježbanje, ispit i kviz. U modu za učenje program bilježi i analizira odgovore korisnika. Nakon što je program detektirao područje s kojim korisnik ima više problema, naredna pitanja se više bave tim područjem. Metodologija koja se koristi prilikom odabira pitanja je Leitherova metoda, odnosno prostorno ponavljanje (Spaced repetition, 2015). Ova vrsta selektivnog generiranja pitanja je specifična za ovaj alat. U modu za vježbanje, analiziraju se podatci koji su prikupljeni do sada od korisnika, od početka vježbanja, te se također selekcija pitanja temelji

na točnosti odgovora iz prošlosti. U ispitnom načinu rada ne radi se nikakva analiza već sva pitanja imaju jednaku šansu pojave. Kviz je način rada koji je zamišljen za kolaborativni rad u učionicama. Umjesto jednog brojača, postoje dva brojača točnih odgovora kako bi učenici mogli lakše raditi u paru.

2.3.1.6. Musition 4

Musition 4 (Musition 4, 2015) je još jedan računalni sustav od poduzeća Rising Software, istog poduzeća koje je razvilo softver Auralia 4. Musition 4 je edukativni softver koji se bavi učenjem isključivo glazbene teorije. 34 različite vježbe su podijeljene u 5 osnovnih kategorija: visina tona, ritam, pojmovi i simboli, harmonija te instrumenti. Sustav je zamišljen tako da na početku korisnik odabere jedan od 12 unaprijed definiranih tečajeva ili kreira po želji svoj. Tečaj se sastoji od prikaza glazbene teorije u tekstualnom i slikovnom obliku. Nakon svake kratke cjeline, slijedi vježba kojom se vježba naučeni dio. Sustav prati rezultate korisnika i može prikazati rezultate prema odraženim lekcijama.

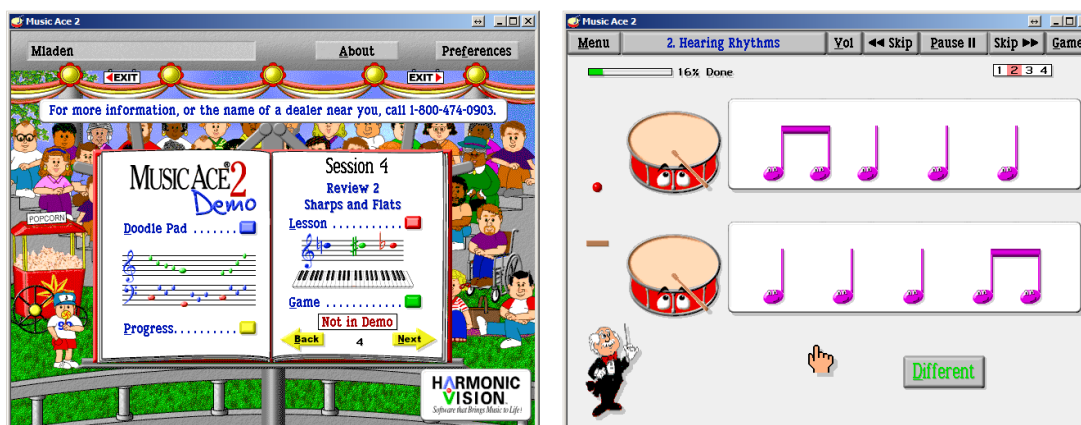


Slika 2.10. Musition 4: Teorija o notnim intervalima

Ovaj alat je također zamišljen kao pomoćni alat za nastavne svrhe. Sustav podržava korištenje više korisnika te za svakoga prati njegove rezultate. U sustavu postoji i administrativni dio koji se odnosi na kreiranje lekcija, testova i selekciju vježbi.

2.3.1.7. Music Ace 2

Music Ace 2 (Music Ace 2, 2015) je zadnje izdanje glazbenog edukacijskog softvera poduzeća Harmonic Vision. Sastoji se od 24 lekcije koje u sebi sadrže preko 2000 glazbenih primjera. Osim 24 lekcije koje su interaktivne i poredane točno prema redoslijedu kojim bi ih korisnik trebao prolaziti, za svaku lekciju kreirana je i po jedna igra sa svrhom dodatnog motiviranja i unaprjeđenja znanja i vještina naučenih u lekcijama. Ovaj sustav je primarno namijenjen mlađem uzrastu zbog svog šarolikog grafičkog sučelja.



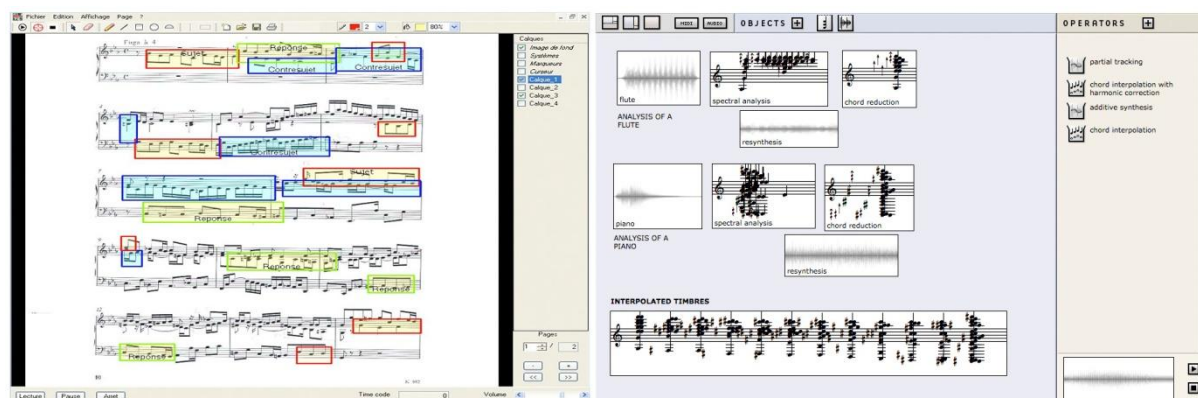
Slika 2.11. Music Ace 2: Glavni meni te lekcija slušanja i prepoznavanja ritmova

Ono što je specifično za ovaj sustav je da su lekcije u potpunosti animirane. Korisnik ne mora čitati tekst i gledati slike već se sav dijalog sluša u auditivnom obliku a slike su pretvorene u interaktivne animacije. Kod svake lekcije korisnik vidi koliko je koraka ostalo do kraja lekcije kao i napredak unutar lekcije. Kada korisnik da netočan odgovor ili krivo izvrši neku aktivnost, postotak odrađene lekcije se smanjuje. No kada korisnik točno odgovara, postotak raste. Kada korisnik dosegne 100%, lekcija je uspješno odrađena. Uz lekcije i igre, u sustav je ugrađen i modul gdje korisnik može kreirati jednostavne melodije crtanjem nota na notnom crtovlju. Kao i kod drugih sustava ovog tipa, korisnik može pratiti svoj napredak. Za igre postoji i rang lista gdje se može vidjeti rezultat svakog pojedinog korisnika koji koristi ovaj sustav. Moguće je također instalirati mrežnu verziju softvera što omogućuje da svaki korisnik koristi sustav na svom računalu a rang lista će biti zajednička. Cilj proizvođača je bio napraviti zabavan, motivirajući sustav koji će biti šarolik i izuzetno interaktivan. Sustav se može koristiti za samostalno vježbanje a može poslužiti i ako pomagalo u razrednoj nastavi. Reprodukcijski zvuk vrši se putem MIDI sučelja.

2.3.1.8. Musique Lab 2

Musique Lab 2 (Puig et al., 2005) je programski sustav kreiran kao pomoćni alat za glazbenu nastavu. Kreiran je u suradnji sa srednjoškolskim profesorima i temelji se na interaktivnoj manipulaciji MIDI zapisa te se koristio u preko 2000 učionica. Musique Lab 2 se sastoji od tri osnovne komponente: komponenta za anotaciju glazbe, komponenta za interaktivno stvaranje glazbe i produkciju, te komponenta za glazbenu kompoziciju.

Komponenta za anotaciju omogućava sinkronizaciju notnog zapisa sa zvučnim zapisom kako bi se lakše pratila neka skladba. U notnom zapisu moguće je kreirati svoje oznake radi glazbene analize. Također ova komponenta se može povezati s preostalim komponentama a sve u svrhu kreiranja nastavnog materijala. Komponenta za stvaranje glazbe omogućava snimanje zvuka na temelju kojeg se kreira spektrogram te na temelju toga se vrši analiza i radi se prikaz odsviranih nota u simboličkom zapisu. U kombinaciji s komponentom za glazbenu kompoziciju, moguće je urediti notni zapis koji je dobiven analizom odsviranog zvuka. Nakon manipulacije zvuka i kreiranja novog sadržaja, moguće je snimiti zvuk u .wav ili .aiff formatu. Komponenta za kompoziciju omogućava manipulaciju glazbenog sadržaja. Kreirane su brojne funkcije putem kojih je moguće modificirati notni zapis kao što je mijenjanje tonaliteta, rastavljanje akorda, kreiranje harmonija i sl.



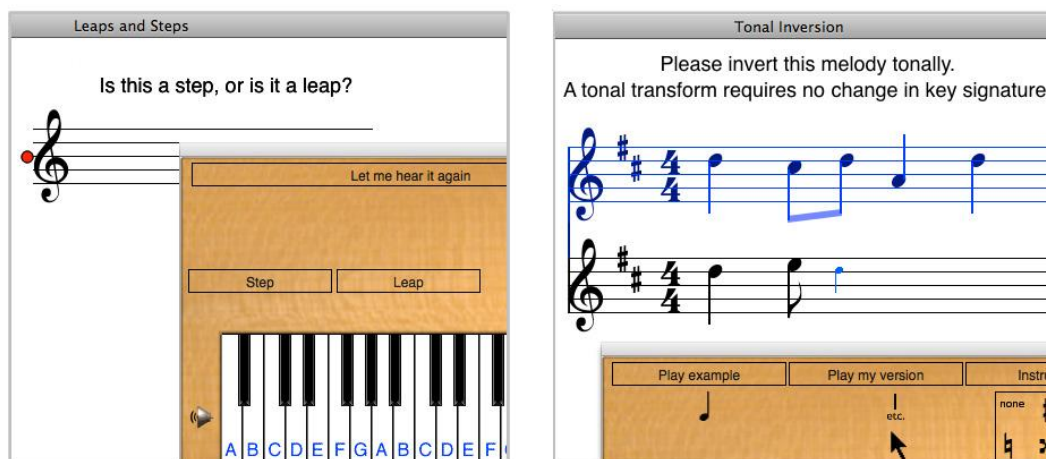
Slika 2.12. Musique Lab 2: Sučelje za anotaciju i sučelje za spektralnu analizu zvuka

Istraživanja su pokazala kako je ovaj računalni sustav pogodan za učenje tonske strukture skladbi, kako bi se razlikovale note, akordi, ljestvice itd. Također je pogodan za vršenje analize strukture glazbenih djela kroz analizu melodijske, ritmičke, harmonijske, instrumentalne i tematske strukture. Kreiran je kao pomagalo za nastavne aktivnosti. Po

svojoj funkcionalnosti, djelomično ulazi i u kategoriju analize glazbenih djela i glazbene kompozicije.

2.3.1.9. Practica Musica 6

Practica Musica 6 (Practica Musica 6, 2015) je još jedan sveobuhvatan računalni sustav koji uči slušne vještine kao i glazbenu teoriju. Ovaj sustav je doživio čak šestu inačicu. Razvila ga je poduzeće Ars Nova koja ima još nekoliko zanimljivih proizvoda iz područja glazbene edukacije. S obzirom da je ovo već šesta verzija ovog sustava, ovaj sustav je sadržajno najbogatiji. U sustav je integrirano 105 različitih slušnih aktivnosti te 120 teoretskih vježbi. Uz sustav dobiva se i digitalna verzija knjige koja se može koristiti i samostalno, no predviđena je kao dodatak korištenju sustava. Ono što je zanimljivo je da se radi o interaktivnoj knjizi koja se osim tekstualnog i slikovnog sadržaja sastoji i od slušnih primjera uz svaku lekciju. Na kraju svake lekcije nalazi se i interaktivni kviz.



Slika 2.13. Practica Musica 6: Prikaz jednostavne vježbe i naprednije vježbe


Sustav je ne samo bogat sadržajem već u sebi sadrži i nekoliko definiranih smjerova prolaska nastavnog sadržaja i aktivnosti. Ovisno o potrebama korisnika, postoje predefinirani putovi selektiranog sadržaja za određenu svrhu, primjerice: osnovne slušne vježbe, osnovni teoretski tečaj, čitanje glazbene notacije i sl. Vježbe se mogu rješavati korištenjem tipkovnice i miša a također moguće je koristiti neki MIDI instrument. Sustav je zamišljen za samostalno korištenje ali se može koristiti i u nastavnom okruženju. Napredak korisnika može se pohraniti putem Interneta tako da učitelj može pratiti napredak učenika.

2.3.2. Računalni sustavi za učenje sviranja glazbenih instrumenata

U nastavku slijedi opis računalnih sustava za učenje sviranja glazbenih instrumenata koji se pojavljuju u znanstvenoj literaturi. Ukratko će se opisati njihove karakteristike i rezultati istraživanja.

2.3.2.1. PianoFORTE

PianoFORTE (Smoliar et al., 1995) je računalni sustav koji je zamišljen kao pomoćno sredstvo u nastavnom procesu iako ga je moguće koristiti i za samostalno vježbanje sviranja klavira. Ideja iza ovog projekta je iskoristiti trenutno raspoloživu računalnu tehnologiju kako bi se dobile preciznije informacije o točnosti izvođenja nekog glazbenog djela. Ovaj sustav se bavi detekcijom 4 vrste parametara u sviranju: dinamika, tempo, artikulacija i sinkronizacija.



Slika 2.14. PianoFORTE: Sučelja za prikaz grešaka

Dinamika sviranja se odnosi na jačinu tj. glasnoću odsviranih nota. S obzirom da je glasnoća relativan pojam, način na koji se detektiraju odstupanja u dinamici je taj da se računa prosječna vrijednost glasnoće svih nota te se nakon toga detektiraju odstupanja od prosjeka. Nakon odsvirane skladbe, korisnik može vidjeti na notnom crtovlju dinamiku odsviranih nota. Dinamika je prikazana bojanjem nota: crvena boja predstavlja note koje su glasnije dok plava boja predstavlja note koje su blaže odsvirane. Intenzitet boje pokazuje intenzitet odstupanja od prosjeka. Kroz ovakav grafički prikaz dinamike, korisnik može postati svjestan svojih dinamičkih oscilacija te korigirati neželjena dinamička odstupanja.

Tempo sviranja odnosi se na brzinu izvođenja skladbe. Nakon odsvirane lekcije, sustav je u stanju prikazati odstupanja u sviranju za svaki set nota u određenom trenutku. Krivulja tempa se dobiva računanjem vremenske razlike između susjednih nota. Nakon računanja vremenske razlike, vrši se normalizacija nota na temelju cijele note. To znači da se polovinke množe s dva, četvrtinke s četiri itd. Nakon normalizacije nota, gleda se razlika u vremenu te se na

temelju tih podataka iscrtavaju dva grafa, jedan za lijevu a drugi za desnu ruku. U slučaju kada se svira više nota odjednom, tada se uzima vrijednost najduže note. Osnova računanja je tempo određene brzine. Ako je doista u skladbi potrebno napraviti određena odstupanja u tempu, to nije uzeto u obzir. No samostalnom analizom ili uz pomoć nastavnika moguće je vidjeti odstupanja u tempu.

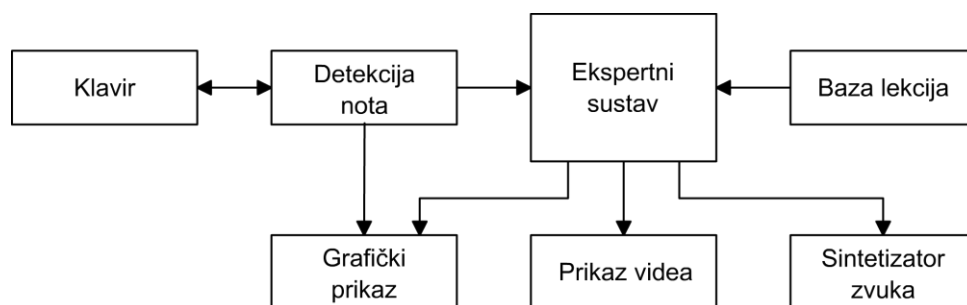
Artikulacija se odnosi na detektiranje trajanja odsviranih nota. Trajanje note je grafički prikazano u obliku pognutog trokuta čiji vrh se nalazi na desnoj strani. Početak trokuta započinje pritiskom note a završava puštanjem note. Kroz ovakav grafički prikaz na notnom crtovlju moguće je vidjeti jesu li note odsvirane prekratko ili predugo. Također kada je potrebno note povezati, moguće je vidjeti dodiruju li se trokuti ili postoji praznina između nota.

I za kraj, detekcija sinkronizacije se odnosi na detekciju jesu li note odsvirane desnom rukom sinkronizirane s notama koje svira lijeva ruka. To je grafički prikazano kroz dvije vertikalnu liniju u dvije boje. Gornji dio linije predstavlja desnu ruku te je obojen ljubičastom bojom dok donji dio linije predstavlja lijevu ruku i obojen je narančastom bojom. Ako su linije poravnate, znači da su ruke sinkronizirane. U slučaju da linije nisu poravnate, to znači da je neka od ruku ubrzala ili usporila.

Iako u sustavu ne postoji nikakva analiza kreiranih grešaka, ovaj sustav na vrlo pristupačan način prikazuje greške koje su nastale prilikom sviranja te čak i početnici mogu vrlo jednostavno vidjeti gdje su pogriješili i odmah dobiti povratnu informaciju o tome vježbaju li ispravno ili ne. Evaluacija sustava u nastavnom okruženju je najavljena no rezultati istraživanja nikada nisu objavljeni.

2.3.2.2. Piano Tutor

Piano Tutor (Dannenberg et al., 1990) je još jedan računalni sustav za učenje sviranja klavira. Po svojoj arhitekturi, Piano Tutor ulazi u kategoriju inteligentnih sustava poučavanja te se temelji na konceptu ekspertnog sustava. Zamišljen je kao zamjena za nastavnika, tj. namijenjen je za samostalno korištenje.



Slika 2.15. Blok dijagram komponenti Piano Tutora

Jasno je da računalni sustav ne može zamijeniti pravog nastavnika no ovaj računalni sustav pokušava oponašati povratne informacije koje nastavnik daje kroz analizu sviranja korisnika. Na temelju odsviranih nota, sustav daje multimedijску povratnu informaciju u nekoliko oblika: video zapis, audio zapis, grafika i glazba.

Ulazne informacije se prikupljaju iz instrumenta koji korisnik svira. Ulazni podatci su u obliku MIDI informacija koje sustav koristi radi naredne analize. Modul za detekciju nota prati odsvirane note te na grafičkom sučelju prikazuje notno crtovlje te poziciju na kojoj se korisnik trenutno nalazi u skladbi. U sustavu je snimljeno pola sata video materijala kao i jedan sat govornih povratnih poruka. Sintetizator zvuka služi kao zvučni izlaz, kako za korisnikovo sviranje, tako i za povratnu informaciju u audio obliku. Sustav se može koristiti na dva načina: poučavanje i vježbanje. Kod poučavanja, sustav u potpunosti usmjerava korisnika kroz bazu lekcija. Kod vježbanja, korisnik sam bira i prolazi lekcije. Autori smatraju kako bi najbolje bilo napraviti nešto između ove dvije krajnosti.

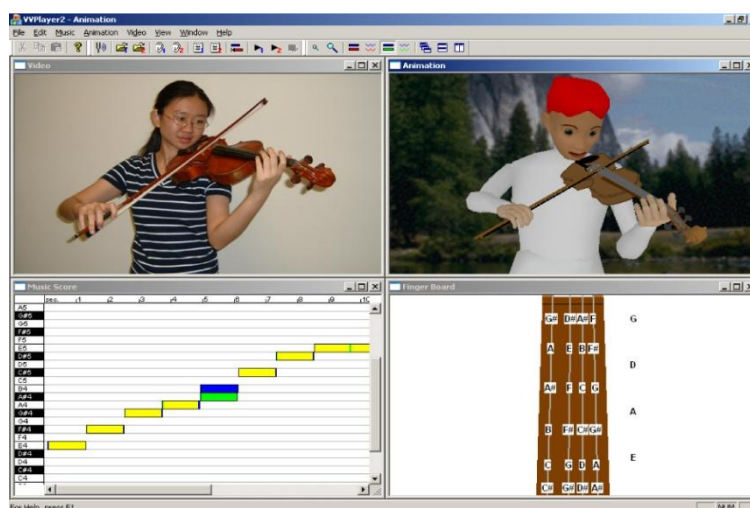
Prilikom poučavanja, sustav odabire narednu lekciju koja se veže na zadnje naučenu lekciju koju je korisnik do sada naučio. Lekcije su povezane tako da svaka lekcija ima određeno potrebno prethodno znanje koje korisnik treba imati. Nakon uspješno odrađene lekcije, u studentski model se upisuje što je korisnik naučio te na temelju tih novih podataka, otključavaju se nove lekcije. Analiza grešaka se vrši tako da se odsvirane note uspoređuju s notama koje su zadane. Sustav može detektirati greške različitog tipa: krivo odsvirana nota, promjena u tempu sviranja, dinamičke greške, prestanak sviranja i sl. Sustav može povratnu informaciju dati i prije nego što lekcija završi, primjerice, ako je korisnik odsvirao previše netočnih nota. Nakon što se detektiraju sve greške, radi se određivanje prioriteta grešaka. Najznačajnije su greške sviranja krive note dok su greške dinamike i tempa manje bitne.

Nakon odabira najvažnije greške, korisniku dolazi povratna informacija u obliku videa, zvuka ili grafike.

Istraživanje uspješnosti ovog sustava provedeno je na 18 učenika. 10 učenika je uspješno završilo sve lekcije dok njih 8 nije u tome uspjelo. Vrijeme koje je bilo potrebno učenicima da završe sve lekcije je variralo od 4 sata do 21 sat. Također, broj lekcija koje su bile prezentirane učenicima je varirao od 36 do 53 (Dannenberget al., 1993). To pokazuje da su sporiji učenici dobili više lekcija dok su oni napredniji dobili manje lekcija. Kroz anketu otvorenog tipa, autori sustava zaključuju kako su reakcije učenika bile pozitivne te da su učenici dobro prihvatili ovakav način učenja. Kratak video o ovom sustavu može se naći na: <http://www.cs.cmu.edu/~music/video/pianotutor.mov>.

2.3.2.3. Digital Violin Tutor

Digital Violin Tutor (Yin et al., 2005) je računalni sustav za samostalno učenje sviranja violine. Sastoji se od nekoliko vizualnih elemenata: video prikaza učenika, grafičkog prikaza nota koje je potrebno svirati (ne standardnim notama već prikazu sličan MIDI zapisu), animiranog 2D prikaza vrata violine te 3D prikaza na kojem digitalni avatar svira violinu.



Slika 2.16. Sučelje sustava Digital Violin Tutor

Sustav se sastoji od 4 osnovna elementa: modul za transkripciju, evaluaciju sviranja, štimer i animator. Sustav funkcionira tako da se korisniku zadaje lekcija koju mora svirati. Pomoću algoritma za audio transkripciju analiziraju se odsvirane note korisnika te se uspoređuju s notama lekcije ili s izvedbom učitelja iste lekcije. Modul za evaluaciju sviranja analizira i

detektira greške koje su nastale tijekom sviranja. To može biti krivo odsvirana nota, neodsvirana nota, intonacijska greška, dinamička greška i sl. Nakon što su detektirane greške, tada se aktivira animator koji putem 2D prikaza vrata i 3D avatara demonstrira ispravan način sviranja učinjenih grešaka. U sustavu je također integriran i štimer koji korisniku pomaže kako bi naštimao svoj instrument.

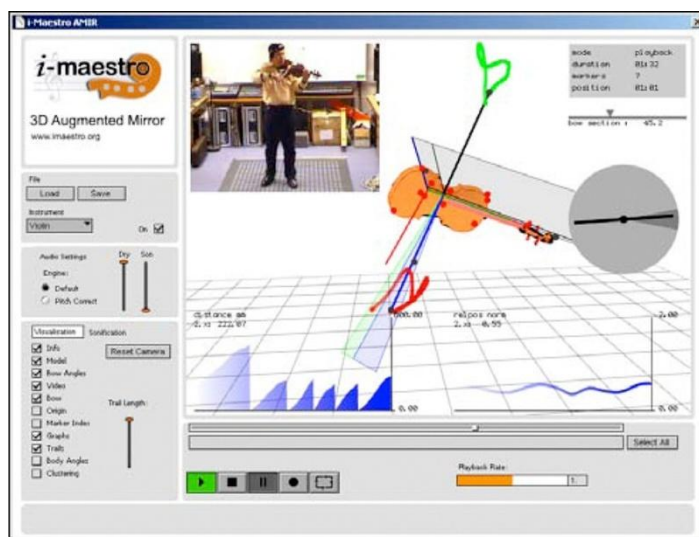
Autori sustava su evaluaciju proveli na 12 učenika (Lu et al., 2008). Nakon nekoliko odsviranih lekcija, učenici su putem upitnika procjenjivali kvalitetu sustava. Istraživanje je pokazalo da je koncept 2D prikaza vrata violine dobar za memoriranje pozicije prstiju za sviranje, a isto tako da je sustav uspješno detektirao greške koje su učenici napravili tokom sviranja. Učenici su smatrali da je ovakav pristup učenju zabavan i koristan. Ono što se nije pokazalo uspješno je 3D prikaz avatara koji svira violinu. Također, učenici su tek prosječnom ocjenom ocijenili modul evaluacije sviranja jer bodovi koje su na kraju dobivali nisu u potpunosti odgovarali njihovom sviranju. Na temelju ovog sustava razvijena je nova verzija, Interactive Digital Violin Tutor sa naprednijom detekcijom nota sviranja koja se temelji na video signalima snimanja lijeve i desne ruke svirača.

2.3.2.4. i-Maestro

i-Maestro (Ng et al., 2008) je računalni sustav koji je razvijen na projektu Europske Komisije u okviru FP6 programa. Na ovom projektu razvijen je sustav koji predstavlja jednu cijelu multimedijску okolinu za glazbenu edukaciju potpomognutu računalnom tehnologijom. Sustav pokriva učenje teoretskog znanja kao i praktičnog znanja tj. sviranja te je usmjeren na učenje sviranja gudaćih instrumenata, posebice violine. Cijeli sustav se sastoji od četiri velike cjeline: alati za produkciju i poučavanje, alati za sviranje i evaluaciju, podrška za kolaborativni rad i školski server.

Alati za produkciju i poučavanje sastoje se od sučelja putem kojeg se mogu kreirati vježbe, lekcije i tečajevi. Kroz ovaj dio sustava uče se teorijska znanja, čitanje i pisanje nota, prolaze se slušne vježbe i sl. Kreiran je modul za generiranje vježbi no taj proces nije u potpunosti automatiziran već korisnik mora sudjelovati u stvaranju (Weyde, 2006). Razvijeni su brojni alati za detekciju i evaluaciju sviranja. Korištenjem brojnih senzora na rukama i violini, kreiran je modul za detekciju pokreta gudala i postave tijela. Na temelju dobivenih podataka iz senzora, sustav kreira 3D prikaz kretanja gudala kroz vrijeme. Interpretacija podataka se

vrši u suradnji s profesorom. Sustav nije zamišljen kao samostalni tutor već kao potpora za postojeći kurikulum (Neubart et al., 2008). Na temelju analize zvuka kreirano je interaktivno notno crtovlje. Sustav na temelju audio analize može pratiti sviranje korisnika i automatski okretati stranice nota. Korištenjem školskog servera, mnoge funkcionalnosti sustava se mogu koristiti na udaljenost stoga je ovaj sustav pogodan i za kolaborativan rad: stvaranje vježbi, zajednički rad na kreiranju nota, analiza podataka preko mreže i dr.



Slika 2.17. i-Maestro: 3D vizualizacija pokreta gudala

2.3.2.5. IMUTUS (Interactive Music Tuition System)

IMUTUS (Schoonderwaldt et al., 2004) je projekt Europske Unije za razvoj interaktivnog računalnog sustava za učenje sviranja frule. Glavni naglasak je na kreiranju sustava za pomoć prilikom vježbanja sviranja no kroz sustav se mogu usvojiti i osnovna teoretska znanja te osnove kompozicije. Automatska analiza sviranja korisnika je glavna komponenta ovog sustava. Sustav se sastoji od baze lekcija, sučelja za prikaz nota, modula za prepoznavanje audio zapisa te na temelju tih podataka kreiranje MIDI zapisa te modula za evaluaciju sviranja. Lekcije su povezane na način da svaka lekcija ima definirano potrebno predznanje te svaka lekcija daje neko znanje. Na temelju do sada stečenog znanja, određene lekcije su dostupne korisniku. Nove lekcije se mogu skidati sa servera sustava te učitelji mogu dodavati nove lekcije na službeni server.

Interakcija sa sučeljem vrši se u 3 faze: faza istraživanja, vježbanja i evaluacije. U fazi istraživanja korisnik proučava lekciju tj. note, što treba odsvirati te također može čuti zvučni

zapis nota koje treba svirati. U fazi vježbanja korisnik svira lekciju uz pomoć metronoma. U fazi evaluacije sustav traži greške u lekciji te daje povratnu informaciju korisniku. Povratna informacija korisniku dolazi u nekoliko oblika. Prvo se dodjeljuje konačna ocjena u obliku bedževa/pehara. Najbolja ocjena su 3 bedža u obliku flaute a najlošija 1 bedž. U interaktivnom prikazu nota greške su naznačene te uz njih dolazi i opisna poruka.



Slika 2.18. IMUTUS: Greška označena strelicom uz opis greške popratnim tekstom


Sustav se temelji na znanju i iskustvu učitelja frule. Na temelju upitnika i intervjuja učitelja kreirana je klasifikacija važnosti tipičnih grešaka. Korisniku se prikazuju maksimalno 3 greške kako ga količina grešaka ne bi obeshrabrila. S obzirom da je frula instrument za koji ne postoji direktno MIDI sučelje, u sustav je ugrađen algoritam za prepoznavanje zvuka. Na temelju informacija o frekvenciji i amplitudi, kreiraju se MIDI informacije o poziciji odsvirane note, trajanju i glasnoći. Sustav se može koristiti za samostalno vježbanje a također može služiti i kao pomagalo u nastavnom procesu. Učitelji mogu davati svoje povratne informacije kroz anotacije na sučelju s notama.

Autori sustava su proveli i istraživanje o korisnosti ovog sustava (Raptis, et al., 2006). Kreirane su dvije grupe, testna grupa od 6 učenika je kod kuće vježbala koristeći IMUTUS sustav dok je kontrolna grupa od 6 učenika vježbala samostalno. Testiranje je trajalo 3 tjedna. Zaključeno je da je sustav jednostavan za korištenje te da je učenicima bilo zabavno koristiti sustav. Profesori su na početku bili skeptični oko korištenja sustava no nakon što su vidjeli efekte na učenicima, prihvatili su sustav kao zanimljivu alternativu. Što se tiče efekta na sviranje, sustav je na kraju evaluirao sve učenike, i testne i kontrolne grupe. Uočeno je da su

učenici koji su koristiti sustav radili manje grešaka krivo odsviranih nota, tj. krivog prstometa. Autori također ističu da su učenici vježbajući uz sustav bili koncentriraniji.

2.3.2.6. VEMUS (Virtual European Music School)

VEMUS (Fober et al., 2007) projekt je nastavak IMUTUS projekta a cilj projekta je kreiranje radnog okruženja za stvaranje virtualne glazbene škole. Ovaj projekt je financiran od strane Europske Komisije u sklopu FP6 programa. IMUTUS projekt je započeo rad na razvoju okoline za vježbanje frule dok VEMUS proširuje područje na niz puhačkih instrumenata: flautu, saksofon, klarinet, trubu i frulu. Sustav se temelji na istom konceptu automatskog detektiranja grešaka u sviranju te davanju adekvatne povratne informacije. Način davanja povratnih informacija je proširen te dolazi u nekoliko novih oblika: anotacije, grafički oblici, tekst, emotikoni, rukom ispisani komentari te zvučne anotacije. Također, sviranje učenika je prikazano i takozvanim objektivnim prikazom sviranja koji se sastoji od grafičkog prikaza audio signala sviranja gdje se vide svojstva poput pozicije nota, trajanje, jačina, intonacija, stabilnost tona te boja tona.



Slika 2.19. VEMUS: Anotacije različitih oblika

Osim za samostalno vježbanje, alat je zamišljen i kao pomagalo u nastavnim aktivnostima. Primjerice, sustav se može koristiti i u vježbanju s učiteljem. Korištenjem tableta, učitelj može davati ručne anotacije na note kako bi usmjerio učenika u sviranju. Također, sustav je zamišljen i kao pomagalo za kolaborativni rad. U nastavnom okruženju može služiti za tipične nastavne aktivnosti: demonstriranje sviranja, ostvarivanje dijaloga između učitelja i učenika, pasivno učenje gdje učenici uče kroz dijalog učitelja s drugim učenikom i sl. Sustav je zamišljen i za rad na daljinu. Korištenjem web kamera, učitelj putem Interneta može vidjeti

učenika kako svira, učenik i učitelj dijele isto notno crtovlje putem kojeg učitelj može davati razne anotacije učeniku. Također, korištenjem video ili audio prijenosa, učitelj može komunicirati s učenikom. Putem sustava učitelj može pratiti napredak učenika. Neka veća istraživanja o uspješnosti sustava nisu provedena no inicijalna istraživanja su pokazala kako je korištenje sustava pozitivno utjecalo na motivaciju učenika na rad te da su učenici koristeći sustav više vježbali od učenika koji nisu koristili kreirani sustav (Tambouratzis et al., 2008).

2.3.3. Komercijalni proizvodi za učenje sviranja glazbenih instrumenata

U nastavku slijedi opis nekoliko značajnijih predstavnika komercijalnih računalnih sustava koji služe u svrhu učenja sviranja nekog glazbenog instrumenta. S obzirom da se ne radi o istraživačkim projektima već stvarnim komercijalnim proizvodima, ovi sustavi su po svom dizajnu doradeniji no u pravilu ne koriste nikakve napredne tehnike kako bi bili inteligentniji ili automatiziraniji.

2.3.3.1. DT-1 V-Drums Tutor i V-Drums Friend Jam

DT-1 V-Drums Tutor (DT-1, 2015) je računalni sustav za učenje sviranja seta bubnjeva a razvila ga je poznato poduzeće koja proizvodi najbolje električne setove bubnjeva, Roland. Ovaj sustav je jedini sustav razvijen isključivo kao edukacijski softver za učenje sviranja seta bubnjeva. Sustav ima dva načina prikaza nota: standardna notacija za set bubnjeva te princip padajućih nota koji možemo vidjeti kod računalnih igara ovog tipa. U notnom prikazu, korisnik treba pratiti plavu liniju koja se animirano kreće po notama i označava gdje se korisnik vremenski nalazi u pjesmi. Iznad plave linije nalazi se i crveni krug koji se kreće tako što skače na naglašene dobe u taktu. Ovisno o lekciji, iznad nota ponekad stoje oznake što treba svirati desnom a što lijevom rukom. Kako korisnik svira lekciju, tada se u stvarnom vremenu iscrtavaju oznake na notama koje korisniku daju do znanja koju notu je odsvirao točno a koju nije. U slučaju ispravnog sviranja, nota će biti zaokružena u plavi krug, no ako je korisnik pogriješio, na mjestu greške nacrtat će se crveni znak "x". U donjem dijelu prozora korisnik može vidjeti set bubnjeva na kojima se prilikom sviranja bojama označava koji element bubnjeva je korisnik udario. Umjesto toga, postoji i prozor koji prikazuje dinamiku odsviranih nota. Korisnik bira koji prozor želi vidjeti. U donjem desnom dijelu sučelja nalazi se prozor za izbor pjesama. Tu korisnik također može izabrati panel na kojem može odrediti tempo vježbe koju svira, može odabrati određeni dio vježbe i vježbati samo taj dio tako da se

taj dio ponavlja u krug. Kod prikaza nota koji se koristi u računalnim igrama, note su prikazane u obliku tankih linija u bojama. Linije se polako pomiču prema dolje. Kada dotaknu rub prozora, korisnik treba odsvirati odgovarajuću notu. Ovaj pogled će pratiti točnost sviranja svake note te prema tome dodijeliti određene bodove. Postoje tri razine točnosti: "izvrsno", "dobro" i "u redu". Točno ovakav prikaz nota je specifičan za ovaj sustav.




Slika 2.20. V-Drum Tutor: notni prikaz padajućih linija i standardna notacija

Iako je ovo edukacijski sustav, količina sadržaja je vrlo skromna. U prvoj verziji ovog sustava, u bazi lekcija nalazila su se 34 kratka primjera. Najnovija verzija u sebi sadrži lekcije za 57 osnovnih ritmova i 60 pjesama (DT-1, 2015). Opravdanje zašto je tako malo sadržaja u sustavu leži u tome da je putem ovog sustava moguće otvoriti bilo koju MIDI datoteku te na taj način korisnik može dodavati vlastite sadržaje u sustav. Na žalost, ne postoji usmjeravanje korisnika u nastavnom sadržaju već on sam bira što i kako će svirati.

Roland je razvio još jedan zanimljiv sustav pod nazivom V-Drums Friend Jam (Friend Jam, 2015). Sustav podržava sviranje na svim verzijama Rolandovih električnih setova bubnjeva. Sustav se sastoji od 66 kratkih pjesama koji traju prosječno dvije minute te su klasificirane prema različitim žanrovima. Pjesme se sastoje od dionica različitih instrumenata no dionica bubnjeva nije snimljena. Za pjesme ne postoje predefinirane note već korisnik sam treba smisliti svoj aranžman koji će svirati. Za 10 pjesama moguće je vidjeti video zapis odsvirane pjesme profesionalca. Nakon sviranja pjesme, korisnik dobiva bodove za sviranje na temelju 5 parametara: izdržljivost, tehnika, varijabilnost uzoraka, preciznost pedal basa te preciznost tempa sviranja. Također, ako korisnik ostvari dobar rezultat, dobiva medalju. Svoje bodove korisnik može usporediti s drugim korisnicima sustava diljem svijeta tako što se korisniku

ispiše rang lista. Rang lista se može prilagoditi na temelju vremena (tjedno, mjesečno, godišnje) i na temelju prostorne lokacije (prema kontinentima, državi).



Slika 2.21. V-Drums Friend Jam: Sučelje za vrijeme sviranja pjesme

2.3.3.2. Playground Sessions

Playground Sessions (Playground Sessions, 2015) je komercijalni proizvod za učenje sviranja klavira. Playground Sessions je razvijen u suradnji sa svjetski poznatim glazbenikom Quincy Jonesom te poznatim poduzećem koje proizvodi glazbene instrumente, Yamahom. Sustav se sastoji od dva osnovna dijela: a) učenje temeljnog znanja, te b) sviranja pjesama. U dijelu učenja temeljnog znanja, sustav se sastoji od niza interaktivnih lekcija koje se sastoje od video zapisa te interaktivnog dijela gdje korisnik treba odsvirati naučene koncepte. Sustav prati napredak svake lekcije te putem davanja bodova i nagrada motivira korisnika. Svoj napredak korisnik može pratiti putem grafova koji ispisuju korisnikov napredak kroz lekcije i vrijeme. Lekcije su poredane po težini od osnova do naprednih koncepata: pokriveno je učenje tehnike sviranja, učenje glazbene notacije, ritma, sviranje po sluhu i dr. Tokom sviranja sustav u stvarnom vremenu prikazuje koje note su ispravno odsvirane a koje nisu. Na kraju lekcije se prikazuje postotak uspješnosti odsvirane lekcije.

Osim učenja kroz lekcije, ovaj sustav uključuje i učenje kroz sviranje popularnih pjesama različitih žanrova. Aranžmani pjesama su prilagođeni u četiri kategorije težine. Pjesme postoje u obliku edukativnih video materijala ili interaktivnog notnog crtovlja. Osim standardnih pjesama koje se nalaze u sustavu, postoji trgovina pjesama na Internet stranicama Playground Sessions sustava gdje korisnici mogu kupiti pojedine pjesme, ovisno o njihovom

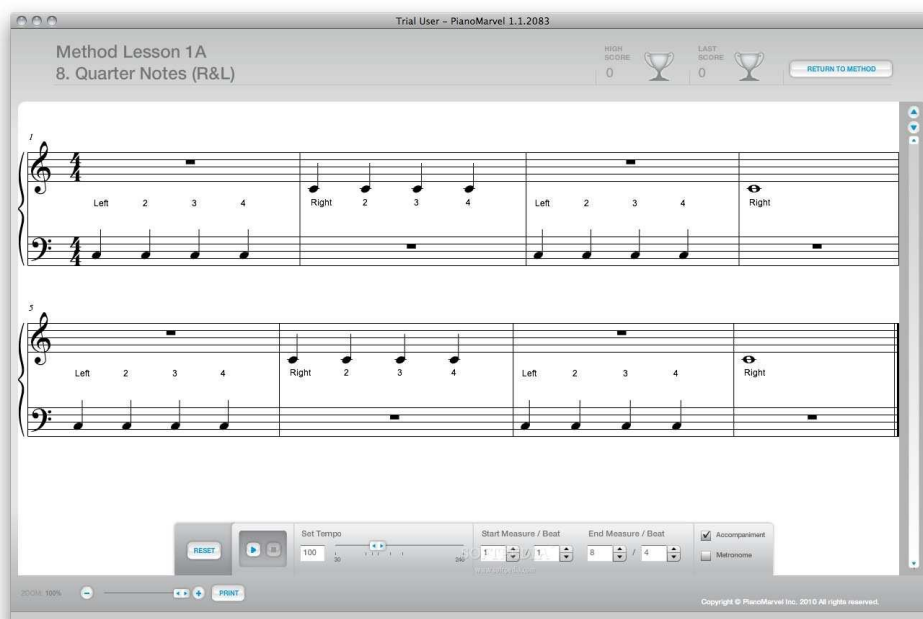
glazbenom ukusu. Putem Interneta moguće je kupiti preko 300 pjesama različitih težina. Kako bi koristio sustav, korisnik mora imati MIDI klavijaturu. Sustav je na vrlo visokom produkcijskom nivou no na niskom nivou automatizacije i inteligencije.



Slika 2.22. Playground Sessions: Prikaz bedževa i bodova nakon vježbe

2.3.3.3. Piano Marvel

Piano Marvel (Piano Marvel, 2015) je još jedan računalni sustav za učenje sviranja klavira. Ovaj sustav se sastoji od preko 1.200 lekcija učenja sviranja klavira. Lekcije su u sustavu poredane po težini. Određene lekcije imaju i video materijale. Nakon odsvirane lekcije, korisnik dobiva odmah povratnu informaciju o tome koje su note točno odsvirane, dodjeljuju se bodovi na temelju točnosti sviranja kao i odgovarajući trofej. I u ovom sustavu je moguće vidjeti određeno koncepte koji su prisutni u računalnim igrama i prije svega namijenjeni dodatnom motiviranju korisnika. Kako bi korisnik osvojio sve zlatne trofeje, potrebno je sve sekcije lekcija odsvirati sa sto postotnom točnošću. Osim lekcija, u sustavu se nalazi i preko 1.000 različitih pjesama. Također su poredane po težini kako bi se korisnici lakše snalazili. Pjesme su u obliku interaktivnog notnog crtovlja.




Slika 2.23. Piano Marvel: Osnovna lekcija - učenje četvrtinki

Autori ovog sustava konstantno kreiraju novi dodatni sadržaj za ovaj sustav te kako se on kreira, besplatno putem nadogradnji ih može koristiti svaki korisnik koji posjeduje ovaj sustav. Osim za samostalno učenje, Piano Marvel se može koristiti i u nastavne svrhe. U sustavu je moguće kreirati "razrede" u kojima su grupirani korisnici. Nastavnik tada kroz sustav može pratiti napredak svakog učenika.

2.3.3.4. Bass Method i Guitar Method

Bass Method (Bass Method, 2015) je računalni sustav poduzeća eMedia za učenje sviranja bas gitare. Ovaj sustav je namijenjen za početnike koji nisu nikad prije svirali bas gitaru. Sastoji se od 140 lekcija koje korisnika uče kako: naštimiti gitaru, svirati standardne note i gitarske tablature, svirati ljestvice, popularne bas dionice i cijele pjesme. U sustavu se nalazi preko 30 snimljenih video materijala koji su snimljeni iz više kutova kako bi korisnik mogao vidjeti kako svirati i s desnom i s lijevom rukom. Primarna metoda je učenje kroz sviranje stoga se u sustavu nalazi preko 200 pjesama koje korisnici mogu naučiti svirati.



Slika 2.24. Bass Method: Sučelje za sviranje pjesama s animiranim vratom gitare

Sučelje se sastoji od interaktivnog notnog crtovlja na kojemu korisnik prati što i kada treba svirati. Uz same note tu je animirani prikaz vrata bas gitare na kojem korisnik može točno vidjeti gdje treba staviti prst na vratu gitare kako bi odsvirao traženu notu. Pjesme se mogu ubrzavati i usporavati kako bi korisnik mogao brzinu prilagoditi svojim sposobnostima sviranja. Također, ako korisnik ima mikrofonski sustav, sviranjem gitare u mikrofonski sustav korisnik može dobiti povratnu informaciju u stvarnom vremenu je li odsvirana nota točna ili ne. Pjesme su snimljene s bas dionicom a i bez nje, stoga je moguće za svaku pjesmu isključiti bas i svirati uz ostale instrumente. Uza sve ovo, u sustavu je uključen i štimer, metronom, snimač zvuka te baza akorda.

Guitar Method (Guitar Method, 2015) je računalni sustav od istog poduzeća samo za učenje sviranja gitare. Sastoji se od 180 lekcija koje pokrivaju sviranje akorda, melodija i prebiranje žica. U sustav je uključeno preko 50 video zapisa na kojima je Kevin Garry, doktor znanosti koji preko 20 godina poučava sviranje gitare, korisnikov digitalni tutor. Sustav je po svojim mogućnostima vrlo sličan Bass Method alatu. Sučelje se sastoji od interaktivnog notnog crtovlja, note mogu biti prikazane standardnom notacijom ili kao tablature. U stvarnom vremenu je osvijetljen akord koji treba svirati kao i smjer trzanja. U sustav je uključeno 70 pjesama. Također, animirani vrat gitare prikazuje što i kako svirati. Ono što je novo u ovoj

verziji sustava su interaktivni kvizovi na kraju lekcija, baza akorda je nešto detaljnija te svaki akord je prikazan u 3 različite pozicije.

Slika 2.25. Guitar Method: Pjesma u tablaturnom prikazu

Za Guitar Method postoji nadogradnja za napredne korisnike. Kreirano je dodatnih 175 lekcija koje uče napredne tehnike sviranja. Osim novih 50 pjesama, uči se i sviranje poznatih solo dionica iz popularnih svjetskih hitova. S obzirom da je gitara polifoni instrument, detekcija zvuka i prepoznavanje nota radi samo za melodijske dionice koje su monofone. Algoritmi za precizno prepoznavanje polifonih instrumenata su u razvoju no još nisu na toj razini da se mogu koristiti u komercijalne svrhe. Vrlo dobre uspjehe u tom području ostvarilo je poduzeće Celemony kroz svoju patentiranu "Direct Note Access" tehnologiju (Celemony, 2015) te poduzeće Jam Origin (Jam Origin, 2015) stvarajući specijalizirane algoritme za određene instrumente.

2.3.3.5. My Guitar, My Electric Guitar, My Piano i My Violin

eMedia je razvila i nekoliko računalnih sustava za poučavanje sviranja namijenjeno djeci. Kreirali su tri sustava: My Guitar, My Electric Guitar, My Piano i My Violin (eMedia, 2015). Do sada su već opisana dva sustava eMedia poduzeća. Ovi sustavi po svojoj funkcionalnosti se ne razlikuju mnogo od već opisanih sustava: interaktivne note, animirani instrument, brojne lekcije (120 za gitare, 100 lekcija za klavir, 160 za violinu), video materijali i sl. Ono što je specifično za ove sustave je da su po dizajnu prilagođeniji mlađoj populaciji, umjesto čitanja materijala oni su prezentirani u audio formatu. Također, svaki sustav ima i petnaestak

interaktivnih igara koje se igraju sviranjem instrumenta. U sustav su uključeni i kvizovi na kojima korisnici mogu testirati naučeno znanje iz lekcija.

U sustavu za učenje sviranja klavira potrebno je imati MIDI klavijaturu te se putem MIDI sučelja ostvaruje komunikacija sa sustavom. Kod violine se koristi mikrofoni te na animiranom vratu violine korisnik može vidjeti je li nota točno odsvirana. Ovakav prikaz može biti izuzetno koristan početnicima, posebno kod sviranja violine jer ona nema pragove poput gitare stoga je teško intonacijski točno odsvirati svaki ton.



Slika 2.26. Mini igra za sviranje gitare, video lekcija za violinu, animirani vrat violine


2.3.4. Računalne igre glazbenog sadržaja

Računalne igre su postale sastavni dio naše socijalne i kulturne okoline (Oblinger, 2004). Sve više vidimo razne elemente računalnih igara u raznim edukacijskim materijalima i sustavima, što pokazuju već opisani komercijalni proizvodi. Igre su posebice pogodne za djecu i tinejdžere. Kroz pametne telefone i tablete, računalne igre su postale dostupne svim dobnim skupinama te danas igre igraju odrasli podjednako kao i mlađa populacija (Griffiths et al., 2003). Igre su posebice pogodne za motiviranje korisnika na rad. Računalne igre ne bi trebalo doživljavati kao neprijatelja već kao dobru priliku za kreiranje novih načina kako učenike bolje zainteresirati za bilo koji edukacijski proces (Prensky, 2003). Interaktivnost, video materijali i animacije su moćna sredstva koja pružaju računala a posebice računalne igre, koje te koncepte pokušavaju implementirati na zabavan način (Klimmt, 2003). Računalnih igara koje se temelje na glazbenom sadržaju ima izuzetno mnogo (List of music video games, 2015). Ovdje ćemo spomenuti samo dva najznačajnija predstavnika koji imaju visoku edukativnu vrijednost.

2.3.4.1. Rock Band serijal

Rock Band serijal kreiralo je poduzeće Harmonix (Harmonix, 2015). Ova serija računalnih igara svoje igrače uvodi u svijet glazbe te igrači postaju glazbene zvijezde. Igra se igra tako da igrači odabiru na početku glazbeni instrument koji žele svirati te igranjem igre napreduju u karijeri. Igrači se mogu opredijeliti žele li svirati električnu gitaru, bas gitaru, set bubnjeva a također moguće je biti i pjevač. Kako bi se ostvario realizam sviranja, uz igru dolazi i poseban set MIDI kontrolera, za svaki instrument po jedan.

Ova serija je prva uvela sviranje seta bubnjeva te vokalno izvođenje. Bubnjevi su posebno interesantni u ovoj igri jer je mehanika sviranja seta bubnjeva identična kao mehanika igranja igre. Osnovni set bubnjeva je dosta reduciran u odnosu na pravi set bubnjeva. Set se u igri sastoji od 4 elementa koji se udaraju palicama te jedne pedale koja se stišće nogom. Kasnije verzije igre su uvele i dodatne tri činele u set što uvelike pomaže tome da se mehanika približi sviranju pravog seta bubnjeva. Svaka pjesma može se svirati na nekoliko razina težine te svaki korisnik treba odabrati težinu koja njemu odgovara. Kroz sviranje pjesama, usvajaju se osnovni koncepti sviranja seta bubnjeva te je doista moguće naučiti svirati osnovne ritmove. Kako igrač napreduje u razini sviranja, tako odabire teže razine i aranžmani postaju sve kompleksniji dok na najtežoj razini, "extreme", za svaki stvaran udarac bubnjeva u pjesmi potrebno je također nešto odsvirati. Osim sviranja samih pjesama, postoji i mod za učenje sviranja seta bubnjeva gdje se uče osnovni rock ritmovi.



Slika 2.27. Rock Band: Sučelje sviranja pjesme i MIDI kontroler za sviranje seta bubnjeva


Izlaskom verzije Rock Band 3, omogućen je način sviranja "Pro". Napravljeni su gitarski MIDI kontroleri sa preko 100 gumba kako bi realističnost sviranja bila blizu sviranja pravih gitara. Također, u načinu "Pro" sviranja je moguće spojiti pravi električni set bubnjeva i električne klavijature. Note koje igrač treba svirati nisu prikazane standardnim notama. Note dolaze u obliku animiranih objekata koje se spuštaju prema igraču. U trenutku kada objekt dođe do dna ekrana, potrebno je odsvirati tu notu. Boje nota su u skladu s elementom koji treba odsvirati na MIDI kontroleru. Pjevanje se izvodi tako da se koristi mikrofoni. Nakon analize visine tona, radi se provjera odgovara li visina tona traženoj visini. Igru mogu igrati 4 igrača od jednom što ovaj sustav čini izuzetno zabavnim za igranje, a također je moguće naučiti i svirati određene instrumente. Svaka igra u sebi sadrži stotinjak pjesama a putem Interneta moguće je kupovati dodatne pjesme. Moguće je kupiti preko 2.000 dodatnih pjesama. Do sada je prodano preko 13 milijuna primjeraka igara iz ove serije a putem Interneta je kupljeno preko 130 milijuna dodatnih pjesama (Harmonix, 2015). Zadnja verzija igre, Rock Band 4 koja je izašla krajem 2015., uključuje i zanimljive koncepte sviranja improvizacija. Na temelju unaprijed snimljenih kratkih uzoraka, njihovim kombiniranjem moguće je svirati različite varijacije solo dionica stvarnih pjesama.

2.3.4.2. Rocksmith i Rocksmith 2014

Rocksmith i Rocksmith 2014 (Rocksmith, 2015) je računalna igra za učenje sviranja električne gitare i bas gitare. Ova igra doista ima za cilj naučiti svoje korisnike svirati prave instrumente. Igra se igra tako što se prava električna ili bas gitara spaja putem posebnog kabela u računalno. Ovaj sustav je razvilo svjetski poznato poduzeće računalnih igara, Ubisoft. Proizvođači igre tvrde da je njihovo istraživanje pokazalo da je 95% korisnika njihovog sustava napredovalo u vještini sviranja gitare koristeći njihovu igru. Na svojoj internet stranici objavili su takozvani "šezdeset-dnevni izazov". Tvrde da redovitim sviranjem u 60 dana korisnik može naučiti sve osnove sviranja gitare.

Glavni dio igre sastoji se od sviranja popularnih pjesama. One su poredane po težini no sama težina pjesama se također tokom sviranja prilagođava korisniku. Ako korisnik ne uspijeva odsvirati traženo, igra se automatski spušta na nižu razinu težine pa je pjesme lake odsvirati. Kada korisnik savlada lakšu verziju, dodavanjem dodatnih tonova, povećava se težina sviranja. Nakon odsvirane pjesme korisnik može vidjeti postotak uspješnosti odsviranih nota.

Osim standardnog sviranja pjesama, postoje i mini igre koje uče osnovne koncepte sviranja gitare ako što je mijenjanje akorda, trzanje žica i sl.



Slika 2.28. Rocksmith 2014: Sučelje sviranja pjesme i mini igra


Rocksmith 2014 je veći naglasak dao na edukativni dio. U igru su uključili preko 85 lekcija koje uče osnovne tehnike sviranja gitare. Također je dodana i mogućnost sviranja improvizacija uz pozadinsku glazbu koja se prilagođava notama koje korisnik svira. Igra je postala vrlo uspješna kako za zabavu, tako i kao alat za učenje sviranja gitare (Rocksmith 2014, 2015). Neke od glavnih zamjerki su nepreglednost sučelja za sviranje pjesama koje se koristi. Poput drugih igara, note nisu zapisane u obliku standardnih nota već u obliku obojenih objekata koji se animiraju kroz prostor prema korisniku. Kada note dođu do iscrtane gitare korisnika, potrebno je odsvirati tražene note. Svaka žica ima svoju boju kako bi bilo lakše razaznati na kojoj žici što treba svirati. Bez obzira na to, s obzirom da gitara ima preko stotinu polja za sviranje, sučelje je i dalje nepregledno te je potrebno jako puno iskustva kako bi se korisnik naviknuo na takav prikaz (Can Rocksmith 2014 Really Teach you to Play Guitar, 2015). Druga glavna zamjerka je sama detekcija odsviranih nota. S obzirom da je gitara polifoni instrument, u igri je implementiran algoritam za polifono prepoznavanje nota. Već smo ranije spomenuli da ovi algoritmi još nisu razvijeni na toj razini da rade bez grešaka. Ubisoft je razvio svoje metode prepoznavanja no one nisu uvijek uspješne stoga nekada sustav ne prepoznaje najbolje što je korisnik odsvirao. No bez obzira na spomenute kritike, Rocksmith 2014 je izuzetno popularan alat za učenje sviranja gitare i u usporedbi sa drugim alatima, Rocksmith 2014 je jedini alat za učenje sviranja gitara koji koristi polifono prepoznavanje odsviranih nota.

2.4. Motivacijske teorije

Kod kreiranje računalnih sustava razvijenih u edukacijske svrhe, motivacija je jednako važna kao i ishodi učenja. Istraživanja su pokazala da računalna tehnologija može izrazito utjecati na motivaciju učenika (Finney & Burnard, 2010; Pitts & Kwami, 2002). Često korišteni koncepti računalnih igara su se također pokazali vrlo uspješni (Denis & Jouvelot, 2005; Koster, 2004). U nastavku će biti dan opis dvije motivacijske teorije koje se koriste u kontekstu povezivanja motivacije i edukacije. Teorija protoka je osnova za razvoj mnogih motivacijskih aspekata sustava kreiranog u ovom istraživanju. Kroz standardizirane upitnike navedenih teorija u fazi evaluacije ispitivao se utjecaj korištenja kreiranog modela i sustava na motivaciju korisnika u usporedbi s alternativnim metodama samostalnog učenja.

2.4.1. Teorija protoka (Flow theory)

"Teoriju protoka" osmislio je Mihaly Csikszentmihalyi te ju je predstavio kroz svoju knjigu "Flow: The Psychology of Optimal Experience" (Csikszentmihalyi, 1990). Csikszentmihalyi ističe da ako se učenika uspije dobro motivirati, tada se maksimizira njegova sposobnost učenja. On "protok" opisuje kao stanje u kojem djelovanje osobe postaje spontano, osoba prestaje biti samosvjesna i gubi osjećaj za vrijeme te sposobnosti osobe u takvom stanju postižu svoj maksimum. Osoba postaje u potpunosti usmjerena na ono što radi i za to pronalazi motivaciju u sebi.



Slika 2.29. a) Ekvilibrij i b) emocionalna stanja kroz odnos vještine i izazova

Csikszentmihalyi 1997. godine objavljuje i model emocionalnih stanja koja se doživljavaju prilikom obavljanja nekog zadatka (Csikszentmihalyi, 1997). Ističe kako emocionalno stanje osobe ovisi o percepciji težine zadatka/izazova te percepciji vještine izvršavanja tog zadatka/izazova. Primjerice, ako osoba dobije zadatak izvršiti neki vrlo neizazovan zadatak koji zahtjeva nisku razinu vještine, tada će se najvjerojatnije osjećati indiferentno, apatično prema tom zadatku. No ako recimo osoba dobije zadatak koji je izazovan a osoba se ne osjeća kompetentno izvršiti zadatak, vrlo brzo ju može preplaviti osjećaj brige i tjeskobe. Kako bi se postigao balans, potrebno je uskladiti vještine osobe sa zadacima koje treba izvršiti. Kako bi se postiglo stanje protoka, zadatci koji se izvršavaju moraju biti interesantni i značajni a korisnici moraju imati adekvatne vještine kako bi ih izvršili.

Csikszentmihalyi izravno dovodi u korelaciju motivacijska obilježja s procesom učenja i razinom uključenosti osobe u tom procesu. Kako bi se optimizirala motivacija u edukacijskom procesu, Csikszentmihalyi ističe 9 dimenzija na koje treba utjecati kako bi se postiglo željeno stanje. U nastavku slijedi opis spomenutih 9 dimenzija uz naznake na koji način računalna tehnologija i adaptabilnost sustava može pozitivno utjecati na korisnika.

1. Moraju postojati jasni ciljevi u svakom trenutku: korisniku u svakom trenutku mora biti jasno što mu je činiti kako bi bila potpuno fokusirana. Računalni sustav mora biti dovoljno intuitivan u korištenju kako ne bi odvrćao pažnju od sadržaja. Putem instrukcijskog modela, korisnika treba omogućiti navođenje kroz bazu znanja i kreirane lekcije. Također, treba imati u svakom trenutku na umu da ciljevi koji se postavljaju pred korisnika budu izvedivi i realni.
2. Mora postojati neposredna povratna informacija o radu korisnika: neposredna povratna informacija je od ključne važnosti kako bi korisnik znao razinu uspješnosti u izvođenja zadataka koji su mu zadani. Kada učenici počinju svirati neki glazbeni instrument, u samostalnom vježbanju se moraju oslanjati na svoju samoprocjenu. Putem adekvatnih mehanizama zaključivanja korisniku je moguće pomoći u samoprocjeni njegovog sviranja te na taj način pomoći u otklanjanju najčešćih početničkih grešaka. Što je povratna informacija preciznija i neposrednija, to je bolji učinak.
3. Mora postojati ravnoteža između percipirane težine i vještine: kako bi se postiglo željeno optimalno motivacijsko stanje korisnika, potrebno je uskladiti težinu zadataka s vještinom korisnika za izvršavanje tog zadatka. Ako dođe do neravnoteže, korisnik može postati tjeskoban zbog osjećaja da nije dovoljno sposoban izvršiti zadatak. S

druge strane, ako su zadatci prelagani, korisnik gubi interes i proces učenja mu postaje dosadan. Kako bi računalni sustav bio adaptabilan po pitanju odnosa težine zadataka i vještine korisnika, potrebno je evaluirati učenikov napredak te na temelju njegovog napretka prilagođavati naredne lekcije, kako bi bile primjerene korisniku. U kreiranom sustavu napravljena je prilagodba lekcija u stvarnom vremenu. Sustav mora biti prilagodljiv tako da oni koji uče sporije dobivaju više lekcija, jer uče sporije, dok oni koji uče brže, dobivaju manje lekcija. U svakom slučaju, lekcije trebaju po težini uvijek biti u skladu s potrebama korisnika.

4. Povezanost zadataka i svjesnosti: u optimalnom slučaju, korisnik je koncentriran na to što radi i postiže željeni cilj a da toga nije ni svjestan. Računalna tehnologija je pogodna za kreiranje ovakvih uvjeta, posebice korištenje koncepata koji se koriste u računalnim igrama (Denis & Jouvelot, 2005). Korisnik ima dojam da se zabavlja a kroz zabavu ujedno i uči te time postiže željeni cilj (Koster, 2013). Elementi koje možemo vidjeti u računalnim igrama mogu pozitivno utjecati na motivaciju korisnika. Primjerice, kada se želi naglasiti da je korisnik nešto dobro obavio ili naučio, tada mu se može dati nagrada u nekom grafičkom obliku što će ga dodatno motivirati da i ostale aktivnosti izvrši sa sličnim uspjehom.
5. Ometanja su izuzeta iz svijesti: korisnik treba biti maksimalno fokusiran na zadatak koji obavlja. Najbolje bi bilo stvoriti takve uvjete rada gdje bi sve vanjske smetnje bile uklonjene. U kontekstu glazbe, za uspješno vježbanje potrebna je tišina i mir. Računalna tehnologija može pomoći u ostvarivanju takve okoline. Korištenjem slušalica zatvorenog tipa moguće je izolirati vanjske zvukove koji bi bila smetnja korisniku. Na taj način se korisnici mogu više usmjeriti u izvršavanje zadatka i ući u svoj kreativni prostor. U takvim uvjetima, korisnici prestaju biti svjesni svoje okoline, gube percepciju o proteklom vremenu te su izuzetno koncentrirani na aktivnost koju rade (Finney & Burnard, 2010).
6. Nema straha od neuspjeha: pojava straha od neuspjeha je često faktor koji djeluje na ljude i blokira njihove sposobnosti. Mnogi ljudi ne vole biti u prisutnosti drugih ljudi kada uče ili općenito, raditi nešto u što nisu sigurni. Istraživanja su pokazala da su učenici opušteniji u situacijama gdje ih evaluira računalno a ne čovjek (Oblinger, 2004; Webster, 2007). Ako korisnik i napravi neku grešku, nitko drugi neće znati za to, samo računalno. Na taj način korisnik je slobodniji i oslobođen pritiska. Kada bude zadovoljan razinom znanja, tada može sam odabrati trenutak kada će to podijeliti s drugima.

7. Samosvijest nestaje: Kada je korisnik maksimalno fokusiran na zadatak, korisnik prestaje biti fokusiran na sebe i svoje potrebe. Ova točka je slična već spomenutom otklanjanju ometanja iz okoline, samo se odnosi na unutarnje stanje čovjeka. Ako je korisnik dovoljno zainteresiran za određenu aktivnost, tada će prestati misliti na svoje potrebe koje nemaju veze sa zadatkom koji obavlja. Računalna tehnologija može pomoći u stvaranju fokusa na zadatak zbog različitog multimedijskog sadržaja koji može u potpunosti okupirati pažnju korisnika.
8. Vrijeme postaje nevažno: kada se korisnik u potpunosti unese u neku aktivnost, tada gubi osjećaj za proteklo vrijeme. To se posebice dešava u situacijama koje su čovjeku ugodne i zabavne. Takva stanja se često dešavaju kod igrača računalnih igara što smo već naveli i ranije. Korištenjem multimedijskog sadržaja kroz zanimljiv kontekst, interaktivnost zadataka, dobro izdizajniranog sučelja, animacije i sl., moguće je stvoriti izuzetno ugodnu radnu okolinu. U takvim uvjetima korisnik više vremena provodi u izvršavanju neke aktivnosti te na taj način ulaže više vremena u učenje i samim time uči više. Istraživanje na VEMUS projektu je pokazalo da su učenici koji su koristili kreirani računalni sustav više vježbali od onih koji su vježbali samostalno (Tambouratzis et al., 2008).
9. Aktivnost postaje sama sebi dostatna (izvorni izraz: *autotelic*): Aktivnost postaje samodostatna kada je korisnik u potpunosti usmjeren na izvršavanje aktivnosti i kada ju izvršava ne radi nekog vanjskog motiva već ju izvršava radi nje same. Aktivnost tako postaje sama sebi svrhom. Učenik uživa raditi aktivnost radi nje same te u takvim okolnostima je potpuno koncentriran i daje svoj maksimum. Postizanje ovakvog stanja kod učenika koji imaju problema s koncentracijom ili pažnjom može uvelike pomoći u usvajanju znanja i vještina.

Što se tiče mjerenja stanja protoka, postoji nekoliko metoda mjerenja (Moneta, 2012). Za procjenu stanja protoka, Csikszentmihalyi je kreirao upitnik protoka (Csikszentmihalyi, 1990). Upitnik se sastoji od pitanja otvorenog tipa te se koristi za procjenu stanja protoka određenih aktivnosti. Druga metoda mjerenja je metoda sempliranja iskustva (Experience Sampling Method). Ova metoda mjerenja se također sastoji od upitnika otvorenog tipa odgovora te se koristi za procjenu stanja protoka u svakodnevnim aktivnostima. Određeni znanstvenici nisu bili zadovoljni ovim metodama te su kreirali svoje upitnike. Upitnik koji će se koristiti u ovom istraživanju je standardizirani upitnik koji su razvili Jackson i Marsh (Jackson & Marsh, 1996).

2.4.2. Teorija samoodređenja (Self-determination theory)

Teorija samoodređenja je motivacijska teorija koju su inicijalno razvili Deci i Ryan te je doradivana od strane mnogih znanstvenika (Ryan & Deci, 2000). Ova motivacijska teorija se bavi prirodnim intrinzičnim tendencijama kako bi djelovanje bilo efikasno i efektivno. Teorija samoodređenja počinje od pretpostavke da su ljudi aktivni organizmi, s težnjom za rastom, napretkom, željom za novim iskustvima i samospoznajom. No, to se ne događa automatski već je za to potrebna podrška iz socijalne okoline. Stoga je veza između aktivnog organizma i socijalnog konteksta osnova za pretpostavke ljudskog ponašanja, iskustva i razvoja.

Teorija ističe kako ljudski socijalni razvoj pokreće zadovoljavanje urođenih psiholoških potreba za kompetencijom, autonomijom i povezanošću. Teorija definira sljedeće motivacijske kvalitete:

- intrinzična motivacija - prirodna motivacija unutar čovjeka koja ga tjera da neko djelovanje, suočavanje s mogućnostima i izazovima za osobni kognitivni i socijalni razvoj.
- ekstrinzična motivacija - to je motivacija koja ne dolazi iz same osobe već dolazi iz vanjskih izvora. Teorija definira više tipova ekstrinzične motivacije, ovisno o razini autonomije čovjeka. Najmanje autonomna je ona gdje postoji zahtjev iz okoline za izvršavanjem zadatka. Najviše autonomna (i djelomično povezana s intrinzičnom) je ona gdje djelovanje možemo poistovjetiti s našim vjerovanjima i osobnim potrebama.
- amotivacija - amotivacija je stanje nemotiviranosti za izvršavanje neke aktivnosti. Amotivacija čovjeka je često povezana s percepcijom nedostatka izazova ili kompetencije za izvršavanjem zadatka. Također, ako je percepcija vrijednosti neke aktivnosti mala, tada često nastupa stanje amotivacije.

Ova teorija se sastoji od 6 mini teorija koje su se razvijene kako bi objasnile motivacijske fenomene koji su detektirani kroz istraživanja. Svaka teorija se bavi jednim aspektom motivacije ili osobnog djelovanja:

1. Teorija kognitivne evaluacije - bavi se intrinzičnom motivacijom, sve od dječje želje za istraživanjem i igrom pa do toga da je intrinzična motivacija izvor kreativnosti tokom cijelog života čovjeka.

2. Teorija integracije organizama - bavi se ekstrinzičnom motivacijom u različitim oblicima kroz regulaciju, identifikaciju i integraciju.
3. Teorija uzročnog usmjerenja - bavi se odnosom pojedinca u odnosu na njegovu okolinu. Postoje tri osnovne orijentacije: autonomnost, kontrola i odobravanje.
4. Teorija osnovnih psiholoških potreba - bavi se već spomenutim psihološkim potrebama koje su urođene u čovjeku: potreba za kompetencijom, autonomijom i povezanošću.
5. Teorija sadržaja ciljeva - bavi se razlikom između intrinzične i ekstrinzične motivacije te utjecajem na dobrobit čovjeka. Vanjski ciljevi poput financijske sigurnosti, slave i popularnosti su u kontrastu s vlastitim napretkom te bliskim povezivanjem.
6. Teorija motivacije odnosa - bavi se ljudskim odnosima, ljudskom potrebom za prijateljstvom i romantičnim vezama, pripadanju grupi. Odnosi ne samo da zadovoljavaju potrebe povezanosti čovjeka, već djelomično i potrebe za autonomijom i izazovom (Self-determination theory, 2015).

Ova teorija je našla svoju primjenu u mnogim područjima a posebno je primjenjiva u području edukacije. Također se primjenjuje i u području zdravstva, odnosa, psihoterapije, psihopatologije, organizacije itd. Intuitivno možemo zaključiti da je motivacijsko stanje povezano s procesom učenja te da je ključna karika za uspjeh, kako bi Prensky rekao, "motiviranog učenika ne može ništa zaustaviti" (Prensky, 2003). Unutar teorije razvijene su skale za mjerenje motivacije u različitim domenama primjene pa tako i u kontekstu edukacije (Self-determination theory, 2015). Ova teorija, kao i službena skala mjerenja, se u ovom radu primjenjuje kao sredstvo mjerenja motivacije u evaluacijskom procesu.

3. RAZVOJ KONCEPTUALNOG MODELA I PROTOTIPA

Nakon što je kreiran pregled postojećih rješenja, kako u znanstvenoj literaturi tako i među komercijalnim proizvodima i računalnim igrama, uočen je nedostatak postojanja kvalitetnog modela inteligentnog poučavanja koji bi integrirao sve one koncepte koji su se pokazali u istraživanjima potencijalno korisni (Hagen, 2004; Roblyer, 2006; Ho, 2006). Ovakvi sustavi bi morali jasno voditi računa o motivaciji učenika primjenom računalne tehnologije (Percival, 2007). I mnogi sustavi to čine, najčešće koristeći neke od koncepata koji se pojavljuju u računalnim igrama (Denis & Jouvelot, 2005) no ne povezuju svoje motivacijske tehnike s motivacijskim teorijama na način da jasno definiraju zašto koriste neki motivacijski element. S obzirom da gotovo nitko nije proveo konkretnu evaluaciju sustava, teško je reći u kojoj mjeri su doista korisnici tih sustava motivirani.

Jednako tako, kako bi jedan edukacijski sustav bio uspješan, bilo bi dobro da ima i neke elemente inteligentnog sustava za poučavanje, kao što su repozitorij znanja koji se može kvalitetno primijeniti kroz interakciju, sposobnost analize sviranja polaznika te davanje povratne informacije na temelju njegove vještine sviranja, odnosno trebao bi imati sposobnost usmjeravanja učenika u pravom smjeru na temelju analize njegovih sposobnosti (Polson & Richardson, 2013). Većina analiziranih alata ima repozitorij znanja u obliku lekcija koje polaznici prolaze. Količina materijala dosta varira od sustava do sustava. Prototipi imaju uglavnom dosta malo sadržaja jer služe tome da se testira pristup učenju dok komercijalni proizvodi imaju nešto veće baze lekcija. Glavni konkurentni alat, DT-1 V-Drums Tutor, u najnovijoj verziji ima 57 osnovnih ritmova i 60 kratkih pjesama (DT-1, 2015). Taj repozitorij znanja je relativno malen no veći problem je što nema nikakvu strukturu sadržaja. Ne postoji određeni redoslijed kojim bi korisnik treba prolaziti lekcije.

Što se tiče davanja povratne informacije, većina sustava ne koristi nikakve mehanizme zaključivanja i usmjeravanja korisnika u njegovom procesu učenja. Većina sustava jednostavno daje povratnu informaciju o tome je li neka nota tokom sviranja korektno odsvirana ili ne. To je zasigurno jedna od najvažnijih karakteristika koju bi računalni sustav ovog tipa trebao imati. Moglo bi se reći da je to osnova na kojoj se onda sve ostalo treba temeljiti. No ako se tu zaustavi, tada se ne iskorištava sav potencijal koji stoji na raspolaganju kako bi povratna informacija bila što efikasnija.

3.1. Ispitivanje inicijalnog interesa potencijalnih korisnika

Statistički podatci koji su navedeni u prvom poglavlju ukazuju na to da mnogi imaju želju naučiti svirati neki glazbeni instrument. Kada se govori o računalnim sustavima za poučavanje sviranje glazbenih instrumenata, pitanje koje se neposredno nadovezuje je koliko bi ljudi bilo voljno učiti svirati neki glazbeni instrument uz neki računalni sustav koji bi im u tome pomagao. Informacija koja također nedostaje je koliko su dosadašnji kreirani računalni sustavi u tome uspješni. S obzirom na vrlo skromne procese evaluacije koji su provedeni u dosadanjim istraživanjima (Dannenberg et al., 1993; Smoliar, 1995; Yin et al., 2005; Raptis, 2006), teško je reći koliki bi uopće bio interes i kakav bi bio krajnji rezultat.

S obzirom da je odgovor na postavljeno pitanje nepoznat, provedeno je istraživanje kako bi se dobili statistički podatci o tome koliko bi ljudi bilo zainteresirano učiti svirati neki glazbeni instrument uz pomoć računala (Konecki, 2015a). U sklopu tog istraživanja postavljena su i specifična pitanja vezana uz konceptualni model koji se razvija na temelju kojeg će se razviti prototip. Istraživanje je provedeno u obliku upitnika. Kreirani upitnik su ispunila 126 učenika/studenta. Odgovori se temelje na standardnoj Likertovoj skali gdje su moguće sljedeće vrijednosti:

1. u potpunosti se ne slažem
2. ne slažem se
3. niti se slažem, niti se ne slažem
4. slažem se
5. u potpunosti se slažem

Dobiveni rezultati su prikazani u tablici 3.1.

Tablica 3.1. Rezultati upitnika o inicijalnom interesu (Konecki, 2015a)

Redni broj	Izjava	Prosječna vrijednost	Standardna devijacija
Q1	Želim naučiti svirati glazbeni instrument.	3,72	1,25
Q2	U svom dnevnom rasporedu nemam vremena pohađati glazbenu školu.	3,89	1,25
Q3	Želio bih imati mogućnost učiti svirati glazbeni instrument svojim tempom i prema svom rasporedu.	4,22	0,97
Q4	Volio bih imati mogućnost učiti svirati glazbeni instrument uz pomoć računala.	3,90	1,19
Q5	Volio bih dobiti povratnu informaciju za vrijeme učenja sviranja glazbenog instrumenta uz pomoć računala.	4,12	1,14

Q6	Želio bih da se glazbene lekcije prilagođavaju mom znanju i tempu učenja.	4,29	0,96
Q7	Smatram da je važno da se sadržaj lekcija prilagođava individualno svakom korisniku.	4,24	1,01
Q8	Smatram da se redoslijed glazbenih lekcija treba prilagođavati individualno svakom korisniku.	4,28	0,92
Q9	Smatram da je automatizirano učenje sviranja glazbenog instrumenta putem računala važno.	3,72	1,02
Q10	Preporučio bih svojim kolegama automatizirani sustav učenja koji se prilagođava korisnikovim vještinama i potrebama.	3,96	1,03
Q11	Smatram da bi automatizirani i adaptabilni način učenja sviranja glazbenog instrumenta olakšao proces učenja.	4,07	0,96
Q12	Smatram da bi automatizirani i adaptabilni način učenja sviranja glazbenog instrumenta učinio proces učenja zanimljivijim.	4,20	0,97

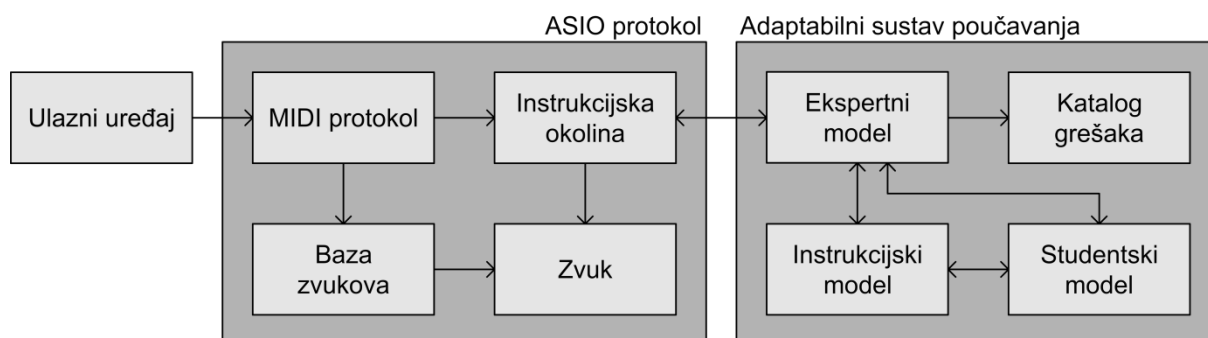
Istraživanje je pokazalo kako je većina ispitanika zainteresirana za učenje sviranja glazbenog instrumenta (58%). Ovi podaci su u skladu sa statističkim podatcima koji su dobiveni putem anketnih upitnika koji su prikazani u prvom poglavlju. Također, većina ispitanika smatra da bi u svom dnevnom rasporedu teško našli vremena još i za glazbenu školu. No kao što je već prije spomenuto, postoje alternative. Statistički podaci su pokazali da sve više i više ljudi hobistički uče svirati sami svirati neki glazbeni instrument. No ovakav način učenja je najčešće nestrukturiran i nije sistematičan (Konecki, 2015a).

Na pitanje da li bi bili voljni učiti svirati glazbeni instrument uz pomoć računala svojim tempom i prema svom rasporedu, ispitanici su također potvrdno odgovorili. Razumljivo da je povratna informacija jako važna u takvom načinu rada. Najveća prosječna vrijednost dobivena je kod pitanja koja se odnose na prilagodbu, tj. adaptabilnost sustava potrebama korisnika: prilagodba znanju i vještinama, prilagodba sadržaja i redoslijeda (Q6, Q7, Q8). Ispitanici su također potvrdili da smatraju kako bi takav način učenja bio lakši i zanimljiviji (Konecki, 2015a).

Na temelju dobivenih rezultata može se zaključiti da ima smisla razvijati adaptabilni sustav poučavanja sviranja seta bubnjeva s ugrađenim mehanizmom prilagođenog dinamičkog generiranja lekcija u stvarnom vremenu.

3.2. Osnovni model adaptabilnog sustava poučavanja sviranja seta bubnjeva (ASPS-B)

Osnovni model adaptabilnog sustava poučavanja sviranja seta bubnjeva zasniva se na temeljnom modelu adaptabilnog sustava poučavanja, tj. temeljnom modelu inteligentnog sustava poučavanja jer sustav sadrži elemente koji se temelje na konceptima adaptabilnost i umjetne inteligencije. Slika 3.1. prikazuje osnovni model na temelju kojeg je kreiran prototip sustava (Konecki, 2014).




Slika 3.1. Osnovni model adaptabilnog sustava za poučavanje sviranja seta bubnjeva

Korisnik sustava sa sustavom može komunicirati putem ulaznog uređaja. To u ovom slučaju može biti akustični ili električni set bubnjeva. Kod opisa razvoja prototipa opisat će se detalji vezani uz različite načine na koji se mogu koristiti ulazni uređaji. No bez obzira na vrstu ulaznog uređaja, ono što sustav prihvaća su informacije putem MIDI sučelja o tome što korisnik svira. Već je spomenuto kako MIDI sučelje ne prenosi zvučne informacije već prenosi samo informaciju o tome kada i kojom snagom je nešto odsvirano. Zato je potrebno imati i kreiranu bazu zvukova koji će reproducirati odgovarajući zvuk prilikom izvršavanja pojedine MIDI informacije. Korisnik naravno mora imati mogućnost odabrati želi li da se generira zvuk na temelju MIDI informacije jer u slučaju sviranja akustičnog seta bubnjeva ili korištenja zvukova iz električnog seta bubnjeva, generirani zvuk mu nije potreban.

Instrukcijska okolina predstavlja sučelje za sviranje putem kojeg korisnik vrši interakciju sa sustavom. Glavni dio sučelja je vizualni prikaz interaktivnog notnog crtovlja putem kojeg korisnik može vidjeti što treba u određenom trenutku svirati. Putem tog crtovlja korisnik dobiva i povratnu informaciju o uspješnosti sviranja lekcije koju svira. Tu je također i vizualni prikaz seta bubnjeva putem kojeg korisnik može vizualno vidjeti svoju interakciju sviranja seta bubnjeva sa sustavom. Na taj način može se utvrditi radi li ulazni uređaj ispravno i je li

sve kalibrirano kako bi korisnik mogao ispravno izvršiti tražene aktivnosti. Putem instrukcijske okoline korisnik odabire i redosljed lekcija. Lekcije osim interaktivnog notnog crtovlja sadrže i video materijale putem kojih korisnik može vidjeti i učiti kako treba odraditi pojedinu lekciju. Istraživanja su pokazala kako je u početnim fazama učenja čitanja nota i ritmičkih uzoraka dobro koristiti apstraktniji prikaz nota (Kuo & Chuang, 2013; Rogers, 1996). Apstraktniji prikaz notnog zapisa se tipično koristi kod većine računalnih igara koje su ovog tipa. S obzirom na to da ovaj sustav nije zamišljen da bude na razini računalne igre već da bude bliže edukacijskom softveru, koristi se standardna notna notacija no usmjerenost u učenju je na praktično znanje. U interaktivnim lekcijama se koristi i metronom kako bi korisnik mogao ispravno pratiti ritmičke uzorke koje treba odsvirati. Tako će konačan zvuk koji korisnik čuje biti kombinacija zvuka seta bubnjeva i metronoma koji dolazi iz sustava. Kako bi sustav mogao generirati konačan zvuk u stvarnom vremenu bez kašnjenja, ove komponente su realizirane putem ASIO protokola koji je već ranije opisan.

Ekspertni model se sastoji od dvije osnovne komponente: baze znanja te mehanizma zaključivanja. Baza znanja je kreirana prema principima instrukcijskog dizajna, prvenstveno prema modelu Dick i Carey-a (Dick & Carey, 2005). Osnova tog pristupa je da je neki skup znanja jedan povezani sustav a ne suma izoliranih dijelova. Model se temelji na povezanosti između konteksta, sadržaja, učenja i instrukcija. Ovakav pogled je prikladan u slučaju gdje se znanje nadopunjuje i gdje je znanje isprepleteno. Najčešće su nova znanja/vještine povezane s prethodnih znanjem, tj. vještinama tako da se nadograđuju. Osnovna ideja je željeno znanje strukturirati u manje cjeline te ga strukturirati na način da se jasno vide veze među lekcijama.



Slika 3.2. Idejni model strukture baze znanja i scenarij prolaska kroz bazu znanja

Sve je potrebno prikazati na jasan i pregledan način kako bi korisnik mogao točno znati uspješnost prolaska pojedine cjeline kao i pojedine lekcije unutar svake cjeline. Za svaku lekciju korisnik će moći odabrati i tempo izvođenja, u slučaju da mu je lekcija preteška, tj. prelagana. Vrijeme koje je potrebno za uspješan prolazak kroz cjelinu će biti varijabilno i ovisit će o uspješnosti korisnika sustava. U slučaju da korisnik neku cjelinu svira bez puno grešaka, puno prije će "naučiti" potrebne lekcije i samim time brže napredovati kroz bazu znanja. S druge strane, netko tko sporije uči će se duže zadržati na nekoj cjelini dok ju u potpunosti ne savlada. Baza znanja se temelji na stručnoj literaturi koja se koristi za učenje sviranja seta bubnjeva, dok je selekcija sadržaja napravljena u suradnji s ekspertom (reference u prilogu F). U bazi znanja nalaze se lekcije koje se sastoje od instrukcijskog multimedijskog dijela koji daje uvod u pojedine lekcije, a tu su također i vježbe zagrijavanja, razni ritmički uzorci i njihove varijacije. U suradnji s ekspertom kreirana je adekvatna baza znanja koja je prilagođena uvjetima evaluacije kako bi se mogla izvršiti evaluacija sustava.

Mehanizam zaključivanja se temelji na konceptu adaptacije lekcija u stvarnom vremenu. Tijekom izvođenja lekcije vrši se evaluacija korisnikovog sviranja te se lekcija tokom izvođenja generira u skladu s potrebama korisnika. U slučaju da korisnik trenutni sadržaj uspješno savladava, taj sadržaj se proglašava naučenim te se počinje dinamički dodavati novi sadržaj u lekciju. Time lekcija postaje sve kompleksnija no ubrza se proces učenja i optimizira se vrijeme koje je potrebno kako bi korisnik uspješno savladao sve ritmičke uzorke neke cjeline.

Uz dinamičku adaptaciju, sustav također detektira vrstu grešaka koje nastaju tijekom sviranja. Vrste grešaka koje se detektiraju su definirane u katalogu grešaka po uzoru na Andersonov model inteligentnog sustava poučavanja (Nwana, 1990). Tu su definirane vrste grešaka koje će se detektirati prilikom sviranja a tu je definirana i njihova klasifikacija, tj. prioritet. Najjednostavnije je detektirati greške koje se temelje na jednom događaju, tj. sviranju pojedine note:

- je li pojedina nota odsvirana u pravo vrijeme, je li odsvirana ranije ili kasnije
- postoji li neka nota koja je trebala biti odsvirana a nije
- postoji li neka nota koja je odsvirana a nije trebala biti odsvirana
- postoji li mjesto gdje je odsvirana kriva nota
- je li pojedina nota odsvirana odgovarajućom dinamikom

Nakon grešaka koje se temelje na pojedinim notama, detektiraju se i greške koje su složenije, tj. greške koje uključuju više nota u evaluaciji:

- postoji li određena kombinacija nota kod koje korisnik češće griješi
- postoji li problem sinkronizacije ruku i nogu, ako da, koja kombinacija
- ako je više nota trebalo u nekom trenutku odsvirati, jesu li one sinkronizirane
- jesu li note odsvirane lijevom i desnom rukom podjednake dinamike
- ako je više nota trebalo u nekom trenutku odsvirati, jesu li ispravne dinamike

Također, moguće je detektirati i greške koje se temelje na cijelim uzorcima ili greške koje nastaju kroz duži period vremena:

- je li korisnik u određenom trenutku počeo ubrzavati ili usporavati,
- postoje li uzorci s većim postotkom grešaka,
- postoji li cjelina ritmičkih uzoraka koja je korisniku teža od drugih cjelina

Na temelju tih informacija korisniku je moguće dati adekvatnu povratnu informaciju kako bi shvatio gdje bi trebao usmjeriti svoj fokus u nastavku vježbanja ili dati posebnu lekciju koja će biti usmjerena upravo na one aspekte koje bi korisnik trebao vježbati kako bi se usmjerio na ispravljanje grešaka koje su najučestalije.

Instrukcijski model je zadužen za odabir strategije poučavanja. Tu su definirane vrste aktivnosti koje korisnik može prolaziti unutar sustava kao i redoslijed aktivnosti kojim bi se aktivnosti trebale izvršavati. Aktivnosti koje će se koristiti u ovom sustavu će biti:

- Video zapisi: instrukcijski video zapisi kao uvod u određenu cjelinu/vježbu
- Vježbanje: mogućnost vježbanja sviranja pojedinog ritmičkog uzorka
- Sviranje: aktivnost prolaska cjeline koja se adaptira u stvarnom vremenu
- Ponavljanje: dinamički generirana vježba svega što je do sada naučeno
- Ispravljanje: vježba za ispravljanje najučestalijih grešaka prilikom sviranja

Sam zamišljeni redoslijed prolaska aktivnosti je prikazan korisniku kroz grafičko sučelje sustava a korisnik sam može također birati koju aktivnost želi dalje prolaziti. Izuzetno je važno da sustav bude fleksibilan u odabiru aktivnosti koje korisnik želi prolaziti. Korisnik mora imati percepciju da on upravlja sustavom a ne da sustav kruto određuje svaku njegovu narednu aktivnost (Csikszentmihalyi, 1990).

U modelu korisnika pamte se bitne informacije o korisnikovom procesu učenja. Prate se aktivnosti koje je korisnik izvršio, koje je sve ritmičke uzorke naučio i s kojim postotkom preciznosti te koji su sve video materijali pregledani. Također, na razini cjelina, prati se koje su sve cjeline naučene i s kojim postotkom uspješnosti, koje su sve vrste aktivnosti odrađene te se također prati koje vrste grešaka su se pojavljivale najviše prilikom sviranja. Većina ovih informacija je korisniku dostupna preko grafičkog sučelja kako bi jasno mogao pratiti svoj napredak.

3.3. Razvoj konceptualnog modela

Sam konceptualni model na kojem se temelji kreirani sustav se zasniva na prepoznatim pozitivnim karakteristikama koje su identificirane u postojećim sustavima. Na tim osnovama izrađena je nadogradnja tako da se omogući prilagodba lekcija u stvarnom vremenu te je napravljena i dodatna analiza prepoznavanja tipova grešaka na temelju koje se generira vježba koja će služiti bržem i boljem otklanjanju učestalih grešaka u sviranju korisnika sustava.

3.3.1. Identifikacija pozitivnih karakteristika postojećih modela učenja sviranja

Na temelju analize objavljenih znanstvenih radova postojećih sustava za poučavanje sviranja glazbenih instrumenata prepoznate su karakteristike koje su se pokazale dobre i one koju su se pokazale kao manje uspješne. U nastavku slijedi opis nekih od najvažnijih karakteristika postojećih modela i sustava te na koji način su one uzete u obzir prilikom kreiranja modela i samog sustava.

PianoFORTE koristi 4 prozora kako bi prikazao različite tipove grešaka: greške dinamike, tempa, artikulacije te sinkronizacije. Iako ovo predstavlja napredniju detekciju grešaka, analizu grešaka mora raditi sam korisnik. Ovakav način rada ne bi bio prikladan za novi sustav jer se analiza grešaka ne može raditi u stvarnom vremenu. Takva vrsta povratne informacije bila bi prekompleksna: teško bi ju korisnik mogao jednostavno percipirati. Stoga je kreirani sustav usmjeren na to da u stvarnom vremenu korisniku prikaže povratnu informaciju koja je najvažnija: je li odsvirana ispravna nota i je li vremenski ispravno odsvirana. Ta povratna informacija se iscertava na samom notnom crtovlju gdje korisnik gleda što svirati. Na taj način korisnik ne mora odvrćati pogled od samog notnog crtovlja i može

reagirati na dobivenu informaciju. Ovaj način davanja povratne informacije se koristi kod mnogih komercijalnih proizvoda, kod računalnih igara ovog tipa i postao je standardni način davanja povratne informacije u ovoj domeni proizvoda. Što se tiče analize ostalih vrsta grešaka (kao što su dinamika ili sinkronizacija), analiza tih vrsta grešaka vrši se na kraju lekcija te ako se pokaže da korisnik učestalo radi iste/slične greške, sustav mu nudi vježbu kako bi se usmjerio na te vrste grešaka.

Piano Tutor u svom modelu ima usmjereno učenje. Lekcije su povezane tako da se nadopunjuju. Da bi korisnik mogao svirati naprednije lekcije mora prvo proći jednostavnije lekcije. Kroz bazu znanja postoji zamišljeni put prolaska kroz grupe lekcija. Također, u sustavu postoji način rada gdje korisnik ima potpunu slobodu vježbati bilo koju lekciju. Autori ovog sustava ističu kako smatraju da je najbolje realizirati nešto između ove dvije krajnosti, gdje je put strogo zacrtan i gdje je omogućena potpuna sloboda (Dannenberg et al., 1993). Na temelju ove informacije, odlučeno je da ASPS-B ima jasno određen put koji će se moći jasno vidjeti kroz sučelje sustava no korisniku će isto tako biti dana i sloboda da sam bira koje lekcije želi prolaziti. Lekcije se generiraju u skladu s korisnikovim načinom rada. Netko će možda krenuti od vježbanja pojedinačnih ritmičkih uzoraka dok će netko odlučiti odmah vježbati cijelu grupu ritmičkih uzoraka, ovisno o percepciji svoje vještine tj. da li će uspješno savladati neku lekciju. S obzirom na to da će sustav pamtit i svaku aktivnost i točno znati koji uzorak je s kojim postotkom preciznosti naučen, reagirat će i generirati lekcije u skladu s tim informacijama.

Piano Tutor također može detektirati više vrsta različitih grešaka: krivo odsvirane note, ubrzavanje/usporavanje u sviranju, greške u dinamici, prestanak sviranja i sl. Većina ovih vrsta grešaka je do sada prokomentirana. U ASPS-B-u će se također detektirati ubrzavanje/usporavanje u sviranju. Također, ideja o detekciji prestanka sviranja je preuzeta iz ovog sustava. Detekcija prestanka sviranja je iskorištena kako korisnik ne bi morao ručno zaustavljati lekciju za vrijeme sviranja korištenjem tipkovnice ili miša. Puno lakše će korisniku biti ako se lekcija sama zaustavi nakon što on prestane svirati. Na taj način korisnik ne mora ustajati od seta bubnjeva i dohvaćati miš ili tipkovnicu. Jednako tako, računalna igra "Rock band" omogućava kompletnu navigaciju sustavom putem seta bubnjeva i korisnik u niti jednom trenutku nema potrebu koristiti neku drugu ulaznu jedinicu. To se pokazalo kao izuzetno efikasna vrsta navigacije stoga je takav način navigacije implementiran i u novokreiranom sustavu.

Digital Violin Tutor koristi virtualni trodimenzionalni prikaz sviranja kako bi se korisnicima pomoglo u savladavanju tehnike sviranja. No ta komponenta se nije u istraživanju pokazala kao vrlo značajna (Yin et al., 2005). Takav prikaz je vrlo neprecizan stoga nema edukacijsku funkciju kakvu su autori željeli postići. Snimljeni video instruktora koji demonstrira sviranje se pokazao kao bolja varijanta u ovom slučaju stoga su za ASPS-B snimljeni video materijali koji demonstriraju sviranje ritmičkih uzoraka koji se nalaze u bazi znanja.

Ono što velika većina ovih alata koristi je virtualni vizualni prikaz instrumenta koji korisnik svira i gdje korisnik može vidjeti povratnu informaciju o svom sviranju. To je korisniku interesantno jer ima vizualnu povratnu informaciju o svom sviranju. To je također korisno kako bi se korisnik uvjerio da sve dobro funkcionira, da sustav ispravno prepoznaje note koje svira. Većina proizvođača električnih setova bubnjeva koristi standardno mapiranje nota no ponekad postoje iznimke i zato nije loše provjeriti ispravnost detekcije.

iMaestro nije zamišljen kao alat za samostalno učenje. Analiza dobivenih podataka u sustavu se treba analizirati u radu s profesorom. Ideja iza toga je osvijestiti korisnika koje greške čini te što mu je činiti kako bi ih ispravio. Naravno, ovakav način rada je pogodan u radu s profesorom jer profesor najbolje može ukazati na to što ne valja i kako to ispraviti. Povratne informacije u ovom sustavu su poprilično kompleksne stoga nije za očekivati da će korisnik sam moći interpretirati dobivene rezultate. Na temelju ovoga moguće je zaključiti da povratna informacija u sustavu mora biti dovoljno jasna i jednostavna kako bi je korisnik mogao razumjeti. Raditi sustav koji nema izravnu povratnu informaciju od profesora zasigurno ima svoja ograničenja i inferioran je načinu rada gdje je uključen stvaran tutor. U iMaestro sustavu je također implementirano automatsko okretanje stranica nota. Praktičnost te mogućnosti se ne mora posebno isticati. Naravno, kada se radi o digitalnom mediju, tada je jednostavno implementirati ovakav način rada što je realizirano u novokreiranom sustavu. Također je osigurano da note budu dovoljno jasne i vidljive kako korisnik ne bi imao problema s vidljivošću. Koristi se pregledan prikaz nota bez puno animacija kako se korisniku ne bi nepotrebno odvrćala pažnja.

Slično kao i kod Piano Tutora, i IMUTUS projekt koristi koncept gdje se na temelju dosadašnjeg znanja omogućuju određene lekcije korisniku. Svaka lekcija ima traženo predznanje koje valja savladati kako bi se otključala nova lekcija. Upravo na taj način je kreirana i baza znanja u ASPS-B-u. Korisniku se sugerira put kojim treba ići. Unutar svake

kategorije (grupe) znanja, lekcije su poredane po težini (prema procjeni eksperta). No korisniku se također ostavlja i prostor za slobodan izbor. Korisnik može birati redoslijed i težinu koja njemu odgovara. Prema teoriji protoka, upravo ovakav način je pogodan za dobru motivaciju korisnika (Csikszentmihalyi, 1990).

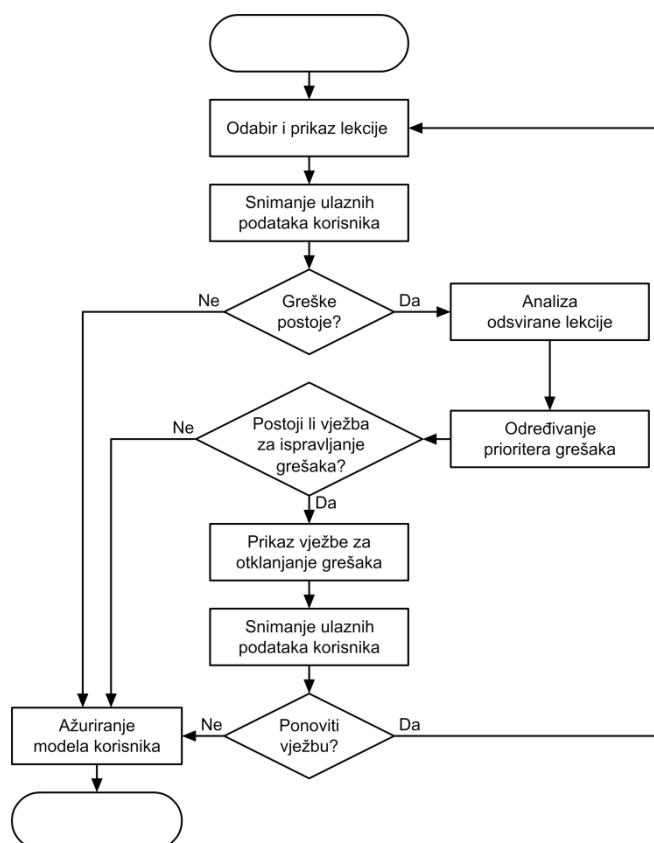
IMUTUS sustav učenja se sastoji od 3 faze: istraživanje, vježbanje, evaluacija. ASPS-B ima sličan koncept. Prva faza je faza istraživanja: instrukcijski video materijali koji daju uvod u ono što treba izvršavati u lekcijama. Također, svaki ritmički uzorak ima video materijal putem kojeg korisnik može vidjeti kako ga ispravno odsvirati. Faza vježbanja i evaluacije je djelomično spojena jer korisnik povratnu informaciju dobiva neposredno za vrijeme vježbanja. U sustavu je faza vježbanja zamišljena kao faza u kojoj korisnik istražuje i vježba pojedine ritmičke uzorke. U fazi sviranja koristi se kombiniranje više ritmičkih uzoraka u cjelinu. Nakon faze sviranja koristi se još i faza ponavljanja gdje se korisniku generiraju lekcije koje se temelje na svemu što je korisnik do tada naučio.

V-Drum Tutor je sustav na kojem se temelji ASPS-B. Osnova sustava je notno crtovlje na kojem se vide točno i netočno odsvirane note. Također, tu je vizualni prikaz seta bubnjeva gdje korisnik vidi svoju interakciju sa sustavom. V-Drum Tutor nema jasan put kroz nestrukturiranu bazu znanja koju ima. Sastoji se od 57 osnovna ritma i 60 kratkih pjesama. ASPS-B ima otprilike 150 ritmičkih uzoraka te ima lekcije koje se generiraju na temelju tih 150 ritmičkih uzoraka a težina lekcija se prilagođava korisniku.

Što se motivacije tiče, tu komercijalni proizvodi imaju prednost. Većina koristi neki sustav nagrađivanja, najčešće kroz neke elemente koji se pojavljuju u računalnim igrama. Tako se najčešće koriste sustavi bedževa i top liste. U ASPS-B-u se također koristi određeni slični motivacijski elementi koji će služiti kao motivatori ali i kao određena korisna povratna informacija. Korisnik dobiva "zvjezdice" za uspješno savladavanje svakog ritmičkog uzorka. Kada neka lekcija bude savladana u potpunosti bez greške, tada se prikazuje i zlatni rub oko te lekcije u izborniku lekcija. Na taj način se pokušava motivirati korisnika da što bolje savlada lekcije a korisnik također ovim putem ima i povratnu informaciju koje lekcije je uspio u potpunosti riješiti tako da zna na koje lekcije se treba vraćati a na koje ne. Isto tako, kada se korisnik želi "zagrijati", tada je dobro krenuti od savladanih lekcija stoga će putem ove povratne informacije znati gdje krenuti.

3.3.2. Postojeći modeli učenja sviranja

Na temelju analize postojećih rješenja, kreiran je dijagram koji prikazuje njihov način rada i način zaključivanja. Naravno, svaki alat ima svoje specifičnosti ali u ovom dijagramu su uzete njihove zajedničke karakteristike. Ovaj dijagram se prvenstveno temelji na modelu rada Piano Tutora jer je on najbliži onome što se želi postići kroz kreiranje novog modela koji bi reagirao na korisnikovo sviranje u stvarnom vremenu i koji bi na prilagođeniji način davao lekcije korisniku. Slika 3.3. prikazuje generalni način rada postojećih rješenja.



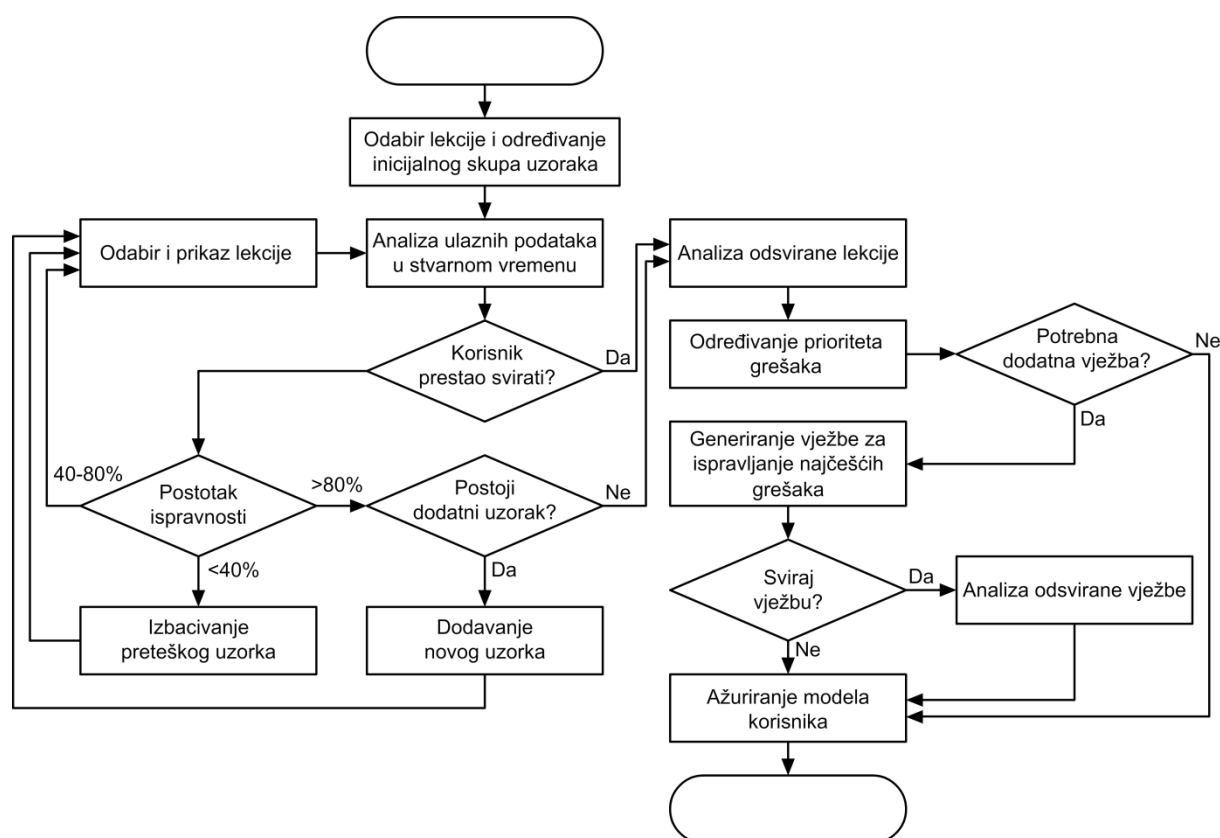
Slika 3.3. Način rada postojećih rješenja

Proces rada uvijek započinje odabirom određene lekcije koja postaje aktivna. Korisnik tada svira odabranu lekciju te se za vrijeme njegovog sviranja dohvaćaju ulazni podatci koji će služiti za analizu sviranja. Kod većine alata korisnik odmah dobiva informaciju o točnosti sviranja lekcije no ta informacija ne služi za izravnu evaluaciju ili usmjeravanje već samo kao povratna informacija korisniku da li lekciju izvršava ispravno. Nakon što je lekcija odsvirana, vrši se analiza ulaznih podataka u slučaju da su nastale greške tokom sviranja lekcije. Većina alata jednostavno ističe gdje su greške nastale te korisnik tada sam treba uočiti gdje je griješio te u nastavku rada usmjeriti svoj napor kako bi te greške izbjegao/ispravio (komercijalni

proizvodi). Nekoliko alata analizira vrstu grešaka te na temelju tih grešaka daje specifične povratne informacije o vrsti pogrešaka (PianoFORTE, IMUTUS, VEMUS, iMaestro). Također, ako postoji određena specifična lekcija koja služi otklanjanju nekog specifičnog tipa grešaka, ona se aktivira te je ponuđena korisniku (Digital Violin Tutor, Piano Tutor). Tokom sviranja dodatne lekcije također se analizira sviranje korisnika te se na temelju odsvirane lekcije te lekcije ispravljanja grešaka ažurira studentski model te se na taj način ažurira informacija o znanju korisnika.

3.3.3. Predloženi konceptualni model učenja sviranja

Predloženi konceptualni model temelji se na osnovi postojećih modela no ima ugrađenu adaptabilnost u stvarnom vremenu te generiranje lekcija vezane uz najčešće greške. Slika 3.4. prikazuje konceptualni model na kojem će se temeljiti kreirani prototip.



Slika 3.4. Konceptualni model ASPS-B-a

Početak učenja započinje odabirom lekcije. Na početku lekcije određuje se inicijalni skup ritmičkih uzoraka koji se nalaze u određenoj lekciji za sviranje. Tijekom sviranja radit će se analiza sviranja te će se lekcija prilagođavati za vrijeme svog trajanja na temelju dobivenih

ulaznih podataka. Kao što je već prije napomenuto, lekcija će trajati koliko god korisnik želi. Da bi se lekcija zaustavila, korisnik treba prestati svirati. Nakon što cijeli uzorak (takt) korisnik ne odsvira niti jednu notu, lekcija se zaustavlja. Na temelju postotka ispravnosti sviranja uzoraka lekcija će se prilagođavati u stvarnom vremenu.

U slučaju da neki ritmički uzorak nakon određenog broja ponavljanja ima visok postotak ispravnosti sviranja, radi se provjera postoji li još ritmičkih uzoraka u grupi ritmičkih uzoraka lekcije koja se svira. Ako postoji još uzoraka, tada se novi uzorak dodaje u skupinu ritmičkih uzoraka koji se sviraju. Za svaki uspješno naučeni uzorak (više od 80%) dodaje se novi uzorak. Stari uzorak se ne izbacuje sve dok ne bude naučen sa stopostotnim uspjehom. Sve dok se uzorci sviraju s 40-80% postotnom ispravnošću, lekcija generira nasumično ritmičke uzorke koji se trenutno uče. U slučaj da korisnik ima većih problema s nekim ritmičkim uzorkom, taj ritmički uzorak se izbacuje i doći će na red kasnije, s težim uzorcima. Uzorci su poprilično poredani unutar lekcije prema težini no može se dogoditi da korisnik ima problema s nekim određenim uzorkom. Na temelju ovih podataka, lekcija se dinamički generira. Kada korisnik nauči sve uzorke sa stopostotnom preciznošću, lekcija će se i dalje generirati. U tom slučaju svaki uzorak koji se nalazi u lekciji ima jednaku šansu generiranja.

Bilo da korisnik želi napraviti pauzu ili je naučio sve uzorke i želi prestati svirati odabranu lekciju, sve što treba je prestati svirati. Nakon što korisnik prestane svirati, radi se analiza svih vrsta grešaka koje su napravljene tokom vježbe. Točnije, sama analiza se vrši tokom sviranja no podatci o tome se obrađuju nakon odsvirane lekcije. Na temelju kataloga grešaka traži se greška najviše razine koja statistički iskače u odnosu na ostale greške. Ako se identificira takva greška tada se generira dodatna lekcija koju korisnik može proći nakon lekcije koju prolazi. Korisnik sam bira želi li dodatnu lekciju ili ne. Tijekom istraživanja se pokazalo da neki korisnici ne žele svirati dodatne lekcije jer su svjesni koje greške čine i radije vježbaju pojedine ritmičke uzorke posebno te se tada nakon vježbanja vraćaju sviranju lekcije koju nisu u potpunosti savladali.

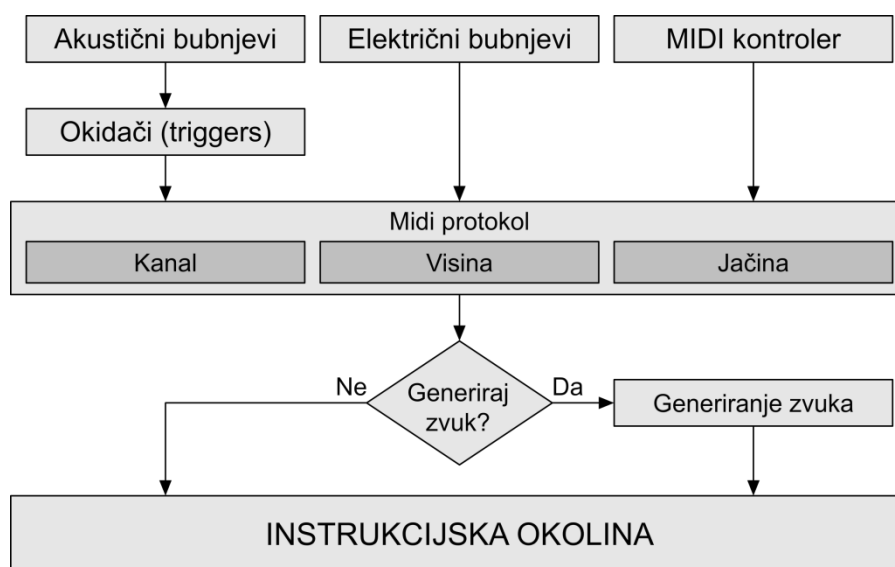
Na kraju slijedi završno ažuriranje studentskog modela. Studentski model se ažurira nakon svakog odsviranog uzorka te na kraju nakon odsvirane lekcije.

3.4. Razvoj prototipa

Kako bi se izvršila adekvatna evaluacija kreiranog konceptualnog modela bilo je potrebno kreirati prototip putem kojeg korisnici mogu isprobati način rada koji je predložen u modelu. U nastavku slijedi opis svake pojedine komponente prototipa. Opisat će se glavne karakteristike sustava te način na koji svaka pojedina komponenta funkcionira.

3.4.1. Ulazni uređaji i generiranje zvuka

Glavna ulazna jedinica putem koje se komunicira sa sustavom je set bubnjeva. Postoji nekoliko različitih scenarija korištenja seta bubnjeva kao ulazne jedinice u sustav. Slika 3.5. prikazuje slikovito na koje je sve načine moguće koristiti set bubnjeva kao ulazni uređaj.



Slika 3.5. Ulazni uređaji ASPS-B-a

Prvi način korištenja je korištenje akustičnog seta bubnjeva. Da bi se ostvarila komunikacija sa sustavom, potrebna je digitalna informacija o sviranju korisnika. Za to su zaduženi okidači, tj. "triggeri" (Roland Triggers, 2015). To su uređaji koji se ugrađuju na set bubnjeva (svaki pojedini element seta) te na temelju vibracija šalju informaciju glavnom modulu u kojem trenutku je neki element seta udaren i kojom jačinom. Glavni modul informaciju pretvara u digitalni signal te se MIDI kabelom ta informacija dalje prenosi u računalo. Na taj način se analogni udarac pretvara u digitalnu informaciju. Postoji i alternativni pristup koji bi koristio sustav mikrofona za svaki pojedini set. Na temelju glasnoće signala u svakom pojedinom mikrofoni moguće je kreirati takvu digitalnu informaciju. Problem s ovim pristupom je taj da

je za svaki element potreban poseban mikrofoni, te je samim tim potrebno imati i miksetu s toliko kanala koliko postoji mikrofona. Na posljetku, postoji problem da mikrofoni koji je primjerice zadužen za snimanje signala malog bubnja također snima i sve zvukove ostalih elemenata stoga je preciznost ovakvog pristupa daleko manja. Alternativa tome bilo bi imati jednostavno dva mikrofona te na temelju jednog zvučnog zapisa raditi prepoznavanje koji element seta je udaren. No to zahtjeva polifono prepoznavanje zvučnog zapisa a ti algoritmi još nisu adekvatno razvijeni kako bi radili sa zadovoljavajućom razinom preciznosti, iako i u tom području postoji napredak (Yoshii et al., 2007; Cakir et al., 2015).

Drugi način dohvaćanja ulaznih podataka je korištenje električnog seta bubnjeva ili bilo kojeg drugog kontrolera koje ima MIDI sučelje (NI Maschine Studio, 2015; Arturia SparkLE, 2015). Prilikom korištenja ovih ulazni jedinica nije potrebna nikakva transformacija ulaznih podataka jer se oni već nalaze u potrebnom formatu. Ovi uređaji se spajaju na računalo putem standardnog MIDI sučelja ili sve češće putem USB sučelja. Ako se koristi MIDI sučelje, potrebno je imati audio sučelje koje može prihvatiti MIDI informacije. Ako se uređaj spaja putem USB sučelja, tada je MIDI informaciju moguće izravno prihvatiti putem računala.

U svakom slučaju, u računalo dolazi MIDI informacija. Tri glavne karakteristike koje treba očitati su na kojem kanalu dolazi informacija, visina note koja se šalje te jačina kojom je odsvirana. Prema standardu koji je ranije opisan, kanal 10 je predviđen za prijenos perkusivnih instrumenata. Jednako tako, prema standardu definirano je i koja visina tona predstavlja koji element bubnjarskog seta (slika 2.3.). Jačina sviranja definirana je jednostavnom varijablom koja može poprimiti vrijednosti od 0 do 127.


Nakon što su MIDI informacije u sustavu, potrebno je odrediti je li potrebno generirati zvuk bubnjeva za korisnika unutar sustava. U slučaju da korisnik svira akustični set bubnjeve, vjerojatno ne želi dodatni generirani zvuk jer svira set bubnjeva koji već proizvodi zvuk. Kod električnog seta bubnjeva moguće je da korisnik želi koristiti zvukove koji se generiraju unutar samog seta bubnjeva jer svaki električni set bubnjeva dolazi s modulom zvukova tj. smplova. Čak i jeftiniji električni set bubnjeva ima u sebi zvukove desetak setova bubnjeva. U slučaju da korisnik želi koristiti smplove iz električnog seta bubnjeva, tada nije potrebno generirati zvuk unutar sustava. U tom slučaju korisniku je još potrebna mikseta s minimalno dva ulazna kanala kako bi mogao dobiti na jednom izlazu zvuk iz seta bubnjeva i zvuk iz računala. U slučaju da korisnik koristi MIDI kontroler ili električni set bubnjeva te želi da se

zvuk generira unutar sustava, potrebno je generirati zvukove koje će korisnik čuti prilikom sviranja. U takvom načinu rada korisniku nije potreban nikakav dodatni hardver kako bi dobio izlazni zvuk.

Za generiranje zvuka seta bubnjeva potrebno je snimiti zvučne zapise pravog akustičnog seta bubnjeva. Način sempliranja seta bubnjeva je vrlo specifičan. Način na koji se danas rade perkusivni virtualni instrumenti je sljedeći:

- svaki element seta bubnjeva se snima na nekoliko razina glasnoće (najčešće 3 do 5)
- unutar svake razine glasnoće snima se nekoliko istih uzoraka (najčešće 3 ili 5)
- za svaki element snima se nekoliko artikulacija po istom principu

Svaki element seta bubnjeva potrebno je snimiti na nekoliko razina glasnoće zato što jači ili slabiji udarac ne mijenja samo glasnoću udarca već mijenja i boju tona. Kod sempliranja seta bubnjeva minimalno je potrebno svaki element semplirati na 3 razine glasnoće: slabo udareno, srednje udareno i jako udareno. Ponekad se snimaju i dodatne gradacije između. Varijabla za detekciju glasnoće kao MIDI informacija može poprimiti 128 različitih vrijednosti. Nakon što su razine snimljene, određuje se raspon unutar kojeg se okida pojedina razina glasnoće. Slika 3.6. prikazuje primjer mapiranja uzoraka za sviranje hihat činele.




Slika 3.6. Mapiranje uzoraka za hihat činelu

Na slici se može vidjeti da prilikom sviranja zatvorene hihat činele postoje dvije osnovne razine uzoraka. Kada je glasnoća prilikom sviranja u rasponu od 0 do 63, tada se sviraju uzorci razine 1 a kada je glasnoća u rasponu od 64 do 127 tada se sviraju uzorci razine 2. Jednako tako postoji gradacija i za otvorenu hihat činelu samo ovaj put u četiri različite razine jer se zvuk sviranja otvorene činele izuzetno brzo mijenja s obzirom na glasnoću sviranja.

Kako bi se postigla dodatna realističnost, unutar svake razine uzoraka ne nalazi se samo jedan zvučni zapis već 3 zvučna zapisa koja su snimljena iste glasnoće. Prilikom sviranja, svaki put

kada svirač udari isti element istom glasnoćom, zvuk je uvijek malo drugačiji. Kako bi se to simuliralo, postoji nekoliko uzoraka koji se cirkularno reproduciraju prilikom sviranja uzoraka iste razine (tehnika nazvana "round robin"). S obzirom da velika većina standardnih pjesama koristi ritam koji ima 4 dobe u jednom taktu, tada se najčešće koristi 3 (ili 5) uzoraka unutar razine. Razlog tome je da uzorak koji je došao u prvom taktu na prvu dobu tek nakon 3 takta opet dođe na prvu dobu. Na taj način će se dobiti osjećaj neponavljanja uzoraka. Slika 3.7. prikazuje redoslijed reprodukcije uzoraka u rasponu od 4 takta.



Slika 3.7. Redoslijed reprodukcije uzoraka unutar razine

Kao što se može vidjeti iz slike, prvi uzorak će na prvu dobu doći tek u četvrtom taktu uzastopnog sviranja. Ovakav pristup uzorkovanja se koristi kod najpoznatijih komercijalnih proizvoda virtualnih setova bubnjeva kao što su Addictive Drums (Addictive Drums, 2015), Superior Drummer (Superior Drummer, 2015), te BFD 3 (BFD 3, 2015).

Kako bi se postiglo minimalno kašnjenje prilikom reprodukcije zvuka (do 10 ms) potrebno je koristiti ASIO (ili WASAPI) zvučni protokol. Na taj način će aplikacija direktno komunicirati sa zvučnom kraticom te omogućiti reprodukciju zvuka u stvarnom vremenu.

3.4.2. Instrukcijska okolina


Instrukcijska okolina predstavlja vidljivi dio putem kojeg korisnik komunicira sa sustavom. U nastavku slijedi opis korisničkog sučelja, način na koji korisnik vrši navigaciju kroz sustav te opis karakteristika sučelja te opis svake pojedine aktivnosti koju korisnik može izvršavati.

3.4.2.1. Karakteristike grafičkog sučelja

Većina sučelja kod alata za učenje sviranja glazbenih instrumenata koristi slične koncepte. Računalna tehnologija omogućuje kreiranje interaktivne animirane okoline koja može dinamički reagirati na sviranje korisnika sustava. To je nešto što nije bilo ranije moguće i upravo animirano notno crtovlje predstavlja osnovu na kojoj se temelje ovakvi alati. Kako bi

sučelje bilo maksimalno prilagođeno korisnicima, provedeno je istraživanje kako bi se utvrdila percepcija korisnika o najvažnijim karakteristikama sučelja. Istraživanje je provedeno na 55 studenta (Konecki, 2015b).

Postoje dva učestala načina prikaza interaktivnog notnog crtovlja. Prvi način prikaza je taj da se notno crtovlje nalazi na fiksnoj poziciji dok pomična crta označava poziciju na kojoj se nalazimo unutar lekcije. Druga mogućnost je ta da je crta fiksna a notno crtovlje se pomiče prema crti. Kada nota dotakne crtu, to je trenutak kada treba odsvirati pojedinu notu. Slika 3.8. prikazuje slikovito ove dvije mogućnosti.



Slika 3.8. Vrsta pomicanja interaktivnog notnog crtovlja

U svrhu istraživanja, kreirana je animacija koja prikazuje ova dva moguća načina prikaza nota. 67,27% učesnika istraživanja je odgovorilo da im je bolji prikaz pomične crte u odnosu na pomični notni zapis. Kod pomične crte, jedino se crta animira stoga je takav način prikaza pregledniji. Iako je možda pomično notno crtovlje "zanimljivije" pa se takav prikaz češće koristi u računalnim igrama ovog tipa (Rock Band, Guitar Hero, Rocksmith). Pokazalo se da takav prikaz zna biti nepregledan i da neprestano pomicanje crte smeta mnogim korisnicima. S obzirom na ovaj rezultat, u novom sustavu je implementirana pomična crta koja će se kretati po fiksnom notnom crtovlju (Konecki, 2015b).

Drugo pitanje koje se tiče animiranja je ako je notno crtovlje fiksno, da li se crta treba pomicati animirano ili treba "skakati" od dobe do dobe i na taj način predstavljati vizualni prikaz kucanja metronoma. Čitanje notnog zapisa nije jednostavna zadaća, pogotovo početnicima. S obzirom na količinu informacija koje korisnik treba percipirati, najbolje bi bilo što manje opteretiti korisnika s dodatnim informacijama. Animacija je informacija koja dolazi neprestano stoga može biti dosta opterećujuća za korisnika. Također, ako se koristi animirana crta, postavlja se pitanje koji je to točan trenutak kada treba notu odsvirati, kada crta dođe do

note ili kada crta dođe u sredinu note. Iako se ovdje radi o vrlo malim vremenskim razlikama, one mogu biti značajne za percepciju korisnika o vremenu kada treba nešto odsvirati (pogotovo kod sporijeg tempa) i samim time mogu utjecati na performanse korisnika. Slika 3.9. prikazuje slikovito ove mogućnosti.




Slika 3.9. Animirana crta ili crta koja skače u taktu na dobe, pozicija detekcije

69,09% ispitanika je odgovorilo da bi radije koristili animiranu crtu u sustavu. No, dva eksperta su sugerirala da se radije koristi crta koja skače. Također, prilikom dizajniranja sustava korisnici koji su testirali sustav su također radije koristili crtu koja skače. S obzirom da su rezultati istraživanja dali suprotno ishod od očekivanog, odlučeno je da će korisniku biti ostavljena opcija da odabere želi li koristiti crtu koja skače ili koja je animirana. Na taj način svatko može odabrati ono što njemu više odgovara. Što se tiče točne pozicije detekcije, 61,82% ispitanika je dogovorilo da bi se detekcija trebala vršiti u trenutku kada crta dođe u sredinu note (to je relevantno samo za animiranu crtu). S obzirom na ovaj rezultat, detekcija se vrši u trenutku kada crta dođe u sredinu note. Također, kod prikaza crte koja skače, ona je iscrtana po sredini note (Konecki, 2015b).

Kod računalnih igara ovog tipa pojavljuje se još jedan način prikaza notnog crtovlja a to je crtovlje koje je animirano i putuje odozgo prema dolje. Iako ponajbolje igre iz ove domene koriste takav način prikaza nota, 78,18% ispitanika je odgovorilo da im je standardni prikaz gdje se note čitaju s lijeva na desno intuitivniji i bolji za učenje (Konecki, 2015b).

Određena istraživanja sugeriraju kako je kod početnika korištenje apstraktnih simbola u boji bolja opcija za prikaz nota (Kuo & Chuang, 2013; Rogers, 1996). Također, kod računalnih igara ovakav način prikaza je češće korišten (Rock Band, Guitar Hero, Rocksmith). U apstraktnom načinu prikaza svakoj vrsti note se također dodjeljuje jedna boja kako bi korisnik lakše mogao prepoznati vrstu note koja dolazi. S obzirom na to da početnici ne znaju čitati

standardnu notnu notaciju, apstraktni prikaz bi im mogao biti jednostavniji za percepciju. Slika 3.9. prikazuje usporedno standardnu notaciju u odnosu na apstraktni tip notacije.



Slika 3.10. Standardno notno crtovlje u odnosu na apstraktno notno crtovlje


89,09% ispitanika je odgovorilo da bi radije koristilo standardnu notnu notaciju. S obzirom da su ispitanici ovog istraživanja tinejdžeri i studenti, tada je vjerojatno jasno zašto su dobiveni ovakvi rezultati. Apstraktni oblici u boji bi vjerojatno bolje kotirali kod nešto mlađe populacije. S obzirom na rezultate ovog istraživanja, u kreiranom sustavu koristit se standardna notna notacija. Takav pristup je vjerojatno pogodniji kod razvoja edukacijskog softvera jer je transfer znanja veći. U slučaju da nakon korištenja sustava netko poželi nastaviti sa svojom edukacijom, tada će imati veću korist od poznavanja standardne notne notacije (Konecki, 2015b).

Spomenuto je da se također u ovakvim sustavima koristi vizualizacija instrumenta koji se svira. Kroz instrukcijske video materijale korisnik može vidjeti što i kako svirati a onda kroz vizualizaciju dobiva povratnu informaciju o tome što svira prilikom vježbanja. Također, putem tog prikaza korisnik može vidjeti da li sustav ispravno detektira njegovo sviranje. Različiti električni setovi bubnjeva ponekad imaju određene razlike u slanju MIDI informacija pa se stoga može vidjeti da li sve ispravno radi ili treba odabrati drugi MIDI profil detekcije nota. 89,09% ispitanika je odgovorilo kako smatra da je dobro imati vizualizaciju seta bubnjeva na ekranu. Također, 92,73% smatra kako bi to pozitivno utjecalo na njihovu motivaciju (Konecki, 2015b). Na temelju ovih rezultata odlučeno je da će korisnik prilikom sviranja na ekranu imati i vizualni prikaz seta bubnjeva. Putem tog prikaza korisnik bi trebao vidjeti što svira i biti motiviraniji prilikom sviranja jer na ekranu ne bi imao samo notni zapis već bi imao i neki grafički sadržaj. Slika 3.11. prikazuje sliku seta bubnjeva koji su izdizajnirani za ASPS-B.



Slika 3.11. Vizualni prikaz seta bubnjeva

Prilikom detekcije grešaka, postavlja se pitanje da li korisniku treba odmah prikazati greške koje je učinio ili pričekati kraj lekcije kako bi mu se prikazali što je dobro odsvirao. Intuitivno je da bi bilo logičnije korisniku odmah dati povratnu informaciju o tome što je učinio dobro a što ne kako bi mogao reagirati na tu povratnu informaciju. No sustav može raditi i tako da korisniku ne ističe greške ali naravno detektira ih u stvarnom vremenu te reagira na njih. Dodatna informacije koje se iscrtavaju na notnom crtovlju mogu korisniku i smetati i odvrćati pažnju. 69,09% ispitanika je odgovorilo da smatraju kako bi povratna informacija o sviranju trebala biti neposredna. Ovi rezultati potvrđuju da je ova informacija važna korisniku. Pogotovo kod početnika koji tek počinju svirati i nemaju razvijen sluh kako bi sami mogli odrediti da li su nešto učinili dobro ili ne, ova povratna informacija je od velike koristi kako bi usmjeravala korisnika u njegovom učenju (Konecki, 2015b). Slika 3.12. prikazuje na koji način će se u sustavu prikazivati povratna informacija korisniku prilikom sviranja vježbe.




Slika 3.12. Povratna informacija u stvarnom vremenu

Što se tiče davanja povratne informacije o vrsti pogrešaka nakon lekcije, 58,18% smatra da je bolje koristiti računalno kreirane lekcije u odnosu na snimljene video lekcije. To je logično jer ako se lekcija kreira dinamički unutar sustava tada onda može biti izuzetno fleksibilna te točno biti usmjerena na ono što kod korisnika treba ispraviti (Konecki, 2015b). To ne znači da se snimljeni video materijali neće koristiti unutar sustava. Kod učenja sviranja novih ritmičkih uzoraka, video materijal je pogodan zato što se on ne treba dinamički prilagođavati korisniku

pa je zasigurno bolje ako korisnik može vizualno vidjeti video snimku eksperta kako svira set bubnjeva a ne samo neku računalnu animaciju. No što se tiče ispravljanja grešaka, dinamički kreirana lekcija je zasigurno fleksibilnija od snimljenog videa. Kvaliteta sustava koji se temelji na snimljenim video materijalima ovisi o tome koliko različitih scenarija video materijali pokrivaju. Često je detektiranje svih scenarija i snimanje video materijala izuzetno zahtjevan posao stoga je elegantnije greške detektirati dinamički te imati mogućnost kreiranja lekcija koje su praktički svaki put drugačije a temelje se na naučenom znanju korisnika te vrsti grešaka koje korisnik čini prilikom sviranja.

3.4.2.2. Dizajn ASPS-B-a

U nastavku slijedi opis korisničkog sučelja ASPS-B-a kao i način navigacije kroz sustav. Sustav je kreiran tako da više korisnika može koristiti sustav na jednom računalu te da svaki korisnik ima svoju bazu podataka u kojoj se zapisuju njegovi osobni podatci o napretku. Prilikom pokretanja aplikacije, prvo što korisnik mora odabrati je svoj korisnički račun. Slika 3.13. prikazuje početni ekran na kojem korisnik bira svoj korisnički račun kako bi mogao krenuti s vježbanjem.



Slika 3.13. Početni ekran ASPS-B-a za odabir profila

Nakon što korisnik odabere svoj korisnički račun, njegovo ime se ispisuje ispod gumba "sviraj" koji korisnika vodi u glavni dio aplikacije. Slika 3.14. prikazuje glavni prozor za odabir lekcija.



Slika 3.14. Ekran za odabir lekcija

U sredini ovog ekrana nalazi se centralni dio koji predstavlja sve lekcije koje su dostupne korisniku. Putem dugačkog klizača koji se nalazi ispod centralnog dijela korisnik može navigirati kroz lekcije koje se protežu s lijeve strane prema desnoj.

U donjem dijelu ekrana nalazi se izbornik za dodatne opcije. Tu korisnik može birati je li potrebno generirati zvuk bubnjeva te želi li prilikom sviranja lekcije koristiti crtu koja je animirana ili koja skače. Pod uputama za korištenje nalazi se niz ekrana koji detaljno opisuju korisničko sučelje te kako koristiti aplikaciju.

Tu je također i klizač za biranje brzine tempa kojim korisnik želi svirati lekcije. Inicijalna vrijednost je 60 a korisnik može birati brzinu od 30 do 90 BPM-a. BPM je kratica za izraz "beats per minute". Broj predstavlja koliko doba se nalazi u jednoj minuti. S obzirom na to da je inicijalna vrijednost 60, to znači da je to brzina gdje se u jednoj minuti nalazi 60 doba, tj. svaka doba traje jednu sekundu.

Desno od odabira tempa nalazi se vizualni prikaz aktivnosti koju korisnik planira odabrati. Ako korisnik postavi svoj miš iznad aktivnosti, tada se iscrtava vizualni prikaz te aktivnosti. Ako je ta aktivnost vježbanje pojedinog uzorka tada se taj uzorak vizualno prikazuje, a ako je ta aktivnost vježba koja se generira, tada se jednostavno ispisuje naziv vježbe. U donjem desnom uglu nalazi se logo aplikacije koji služi za odabir aktivnosti za ispravljanje učestalih grešaka (kada je ona dostupna). U samom uglu nalazi se gumb "izlaz" za izlaz iz aplikacije.

Što se tiče dizajna centralnog dijela aplikacije, svaka lekcija koju korisnik može odabrati ima svoju ikonicu. Slika 3.15. prikazuje 4 temeljne vrste aktivnosti koje se nalaze u centralnom dijelu odabira lekcija.



Slika 3.15. Vrste aktivnosti (slika iz uputa za korištenje sustava)

Najjednostavnija lekcija je video zapis. To je instrukcijski dio gdje se daju neke osnovne informacije korisniku poput upoznavanja sa sustavom, glazbena teorija, motivacijska poruka i sl. Slika 3.16. prikazuje prozor koji se otvara prilikom odabira video lekcije.



Slika 3.16. Prozor za reprodukciju video zapisa

U ovom prozoru korisnik može vidjeti video zapis koji je odabran. Također, tu su dva gumba: "ponovi" i "izlaz". Klikom na gumb "ponovi" video zapis se prikazuje ponovno iz početka dok se klikom na gumb "izlaz" zatvara prozor s video zapisom.

Sljedeća vrsta aktivnosti je sviranje pojedinog uzorka. Slika 3.17. prikazuje prozor koji se otvara prilikom aktiviranja ove aktivnosti.



Slika 3.17. Prozor za vježbanje pojedinog uzorka

U srednjem gornjem dijelu ekrana se nalazi naziv kategorije unutar koje se nalazi ritmički uzorak koji je prikazan te njegova numeracija. U gornjem desnom uglu ekrana nalazi se gumb "VIDEO" putem kojeg korisnik otvara video zapis i može vidjeti kako ekspert ispravno svira trenutno odabrani ritmički uzorak.

U sredini ekrana se nalazi interaktivno notno crtovlje putem kojeg korisnik svira ritmički uzorak. Zelenim "o" znakom se označava nota koja je ispravno odsvirana dok crvenim "x" znakom se označava krivo odsvirana nota. Crta koja označava vizualne otkucaje metronoma je djelomično transparentna te je iscrtana plavom bojom. S desne strane nalazi se ukupni postotak točnosti sviranja uzorka dok se ispod te vrijednosti nalazi informacija koliko puta za redom je korisnik odsvirao uzorak bez greške. S obzirom da je za stopostotni učinak potrebno odsvirati 4 puta uzorak bez greške, ispisu broja je dodano na kraju "/4" kako bi korisnik znao koliko još puta treba odsvirati uzorak kako bi ostvario stopostotni uspjeh. Boja ispisa postotka

uspješnosti se mijenja s obzirom na vrijednost. Ako je postotak manji od 50% tada je boja crvena, ako je između 50% i 95% tada je postotak ispisan žutom bojom dok je za raspon od 95% do 100% postotak ispisan zelenom bojom.

Na dnu ekrana se nalazi vizualni prikaz seta bubnjeva gdje korisnik može vidjeti svoju interakciju sa setom bubnjevima vizualno. Kada korisnik udari u neki bubanj, tada on na kratko zasvijetli plavom bojom. U samom desnom uglu nalazi se gumb za izlazak iz trenutne lekcije.

Centralna aktivnost ASPS-B-a je aktivnost sviranja. Slika 3.18. prikazuje prozor koji se prikazuje prilikom odabira ove aktivnosti.



Slika 3.18. Prozor za sviranje ritmičkih uzoraka određene kategorije


U gornjem desnom kutu ekrana nalazi se naziv lekcije te ispod također piše vrsta aktivnosti. U gornjem lijevom kutu nalazi se predtakt lekcije koji služi za vizualno otkucavanje inicijalne 4 dobe kako bi korisnik znao kada krenuti sa sviranjem.

Centralni dio sastoji se od dva reda interaktivnog notnog crtovlja. U svakom redu nalazi se 4 takta lekcije. Plava crta označava poziciju na kojoj se trenutno vremenski korisnik nalazi unutar lekcije. Nakon što korisnik odsvira prvi red, crta se pomiče u drugi red. Nakon odsviranog drugog reda, crta se pomiče natrag na prvi red. Tijekom sviranja drugog reda,

nakon odsviranja 2 takta, generira se novi prvi red nota. Jednako tako u nastavku sviranja, kada korisnik odsvira prva dva takta prvog reda, generira se novi drugi red. Tako se lekcija generira u krug sve dok korisnik ne prestane svirati.

U donjem dijelu ekrana s lijeve strane nalazi se numeracija svih ritmičkih uzoraka koji se nalaze u ovoj lekciji. Putem boje korisnik može vidjeti koji su uzorci naučeni (zelena boja), koji su djelomično naučeni (žuta boja) te koji još nisu naučeni (crvena boja). U sredini se nalazi vizualizacija seta bubnjeva kao i kod sviranja pojedinog uzorka. S desne strane mogu se vidjeti dva podatka: ukupan postotak naučenih uzoraka trenutne lekcije te također podatak koliko ritmičkih uzoraka je naučeno sa stopostotnim uspjehom. Na samom dnu se nalazi gumb za izlaz iz trenutne aktivnosti.

Vrlo slična vrsta aktivnosti je aktivnost za ponavljanje. Slika 3.19. prikazuje prozor koji se pojavljuje prilikom sviranja ove aktivnosti.



Slika 3.19. Prozor vježbe za ponavljanje

Iako je sadržajno ova aktivnost drugačija, iz perspektive dizajna sučelja ona je gotovo identična. Jedina razlika je u oznakama koje se nalaze u donjem desnom uglu. Aktivnost ponavljanja je fiksne dužine a ta dužina je 32 takta. Postotak koji se ovdje prikazuje na početku ima vrijednost nula posto te kako korisnik svira pojedine taktove, tako taj postotak raste ovisno o preciznosti sviranja svakog pojedinog takta. Postotak se računa apsolutno u

odnosu na svih 32 takta. Na taj način postotak od početka vježbe neprestano raste i u niti jednom trenutku ne pada. Takav način računanja je odabran kako bi bio motivirajući za korisnika. U slučaju da se odabrao model gdje bi se postotak računao relativno u odnosu na samo odsvirane taktove tada bi taj postotak rastao i padao. Odmah nakon prvog takta taj postotak bi mogao imati vrijednost 100% i nakon prve greške se više nikada ne bi mogao vratiti na 100%. Ispod postotka nalazi se podatak koji korisniku govori koliko je taktova do sada odsvirao. Pogledom na taj podatak korisnik može vidjeti koliko mu je još taktova ostalo do kraja lekcije.

Aktivnosti vježbanja, sviranja i ponavljanja imaju nekoliko zajedničkih svojstava. U prozoru za odabir lekcija mogu se sumarno vidjeti karakteristike za svaku lekciju. Slika 3.20. prikazuje grafička svojstva spomenutih aktivnosti.



Slika 3.20. Povratna informacija i motivacija za svaku aktivnost

Svaka aktivnost ima svoj naziv. Naziv za pojedine ritmičke uzorke je njihov redni broj dok aktivnosti sviranja i ponavljanja nose ime kategorije ritmičkih uzoraka koju predstavljaju. Uz aktivnost pojavit će se zelena kvačica ako je pogledan instrukcijski video koji se veže uz zadanu aktivnost. Ako aktivnost nema instrukcijski video (aktivnost sviranja i ponavljanja) tada se zelena kvačica dobiva nakon barem jednog izvršavanja aktivnosti. Uz svaku aktivnost (osim video zapise) stoji i postotak uspješnosti kao i broj zvjezdica koji se temelji na postotku uspješnosti obavljanja pojedine aktivnosti. Na slici 3.19. se može vidjeti za koji postotak uspješnosti se dobivaju jedna, dvije ili tri zvjezdice. Kada korisnik u potpunosti savlada neku aktivnost sa stopostotnim učinkom te unutar te aktivnosti ne postoji ništa što je moguće unaprijediti, tada ta aktivnost dobiva zlatni rub čime se označava da je ona u potpunosti savladana. Putem ovih povratnih informacija korisnik može vrlo brzo vidjeti svoj napredak u učenju.

Što se tiče navigacije sustavom, najbolji način bi bio da kada korisnik jednom sjedne za set bubnjeva više ne mora od njih ustajati i koristiti neke druge dodatne ulazne jedinice. Naravno, sustavom se može navigirati korištenjem miša no također je omogućena navigacija sustavom korištenjem seta bubnjeva. Slika 3.21. prikazuje na koji način se navigira sustavom korištenjem seta bubnjeva kao ulazne jedinice.



Slika 3.21. Upute kako navigirati sustavom setom bubnjeva

U glavnom izborniku lekcija, zeleni rub oko lekcije označava trenutno odabranu lekciju. Udaranjem u visoki tom, odnosno duboki tom, selekcija lekcije će se pomicati na sljedeću, odnosno prijašnju lekciju prema predviđenom putu prolaska lekcija. Udaranjem u mali bubanj odabire se trenutno selektirana lekcija. Za odabir posebne lekcije (lekcija ispravljanja učestalih grešaka), kada je dostupna, potrebno je u glavnom izborniku udariti u "ride" činelu.

Unutar lekcije sviranja pojedinih ritmičkih uzoraka udarcem u mali bubanj se pokreće proces sviranja lekcije. Lekcija se zaustavlja tako da korisnik jedan takt ne odsvira niti jednu notu. Za prikaz instrukcijskog videa, korisnik treba udariti "ride" činelu. Donji duboki tom služi za izlazak iz lekcije te povratak u glavni izbornik. Kod prikaza instrukcijskog videa, ako korisnik udari hihat činelu tada će se video ponovno prikazati. Navigacija je ista kod lekcija sviranja i ponavljanja. U tim aktivnostima jedino nema instrukcijskog videa za odabir. I naravno, za vrijeme sviranja lekcije, set bubnjeva jednostavno služe za sviranje. Na ovaj način korisnik može učestale radnje navigacije izvršiti izravno setom bubnjeva.

3.4.3. Ekspertni model

Ekspertni model se sastoji od dvije osnovne komponente: baze znanja te od mehanizama zaključivanja. Baza znanja predstavlja temeljni edukacijski materijal koji će korisnik učiti tijekom korištenja sustava dok su mehanizmi zaključivanja zaduženi za analizu ulaznih podataka od korisnika te davanja adekvatne povratnih informacija na temelju kojih korisnik sustava može optimizirati proces učenja/vježbanja.

3.4.3.1. Baza znanja

Kao što je već spomenuto, baza znanja je kreirana prema Dick & Carey modelu instrukcijskog dizajna. Njihov temeljni model instrukcijskog dizajna se temelji na osnovnih devet koraka koji se u suštini bave pitanjima što učiti te na koji način (Dick & Carey, 2005):

1. Odrediti jasan cilj, što korisnik treba naučiti
2. Odrediti koje vještine korisnik mora naučiti
3. Identificirati prethodno znanje potrebno za savladavanje lekcije
4. Odrediti jasne ishode učenja - što će korisnik znati nakon lekcije
5. Testiranje što korisnik zna nakon provedene lekcije
6. Određivanje plana lekcije - demonstracija onoga što se želi naučiti
7. Priprema potrebnih materijala za određenu lekciju
8. Evaluacija uspješnosti provedbe lekcije
9. Evaluacija cjelokupnog procesa učenja

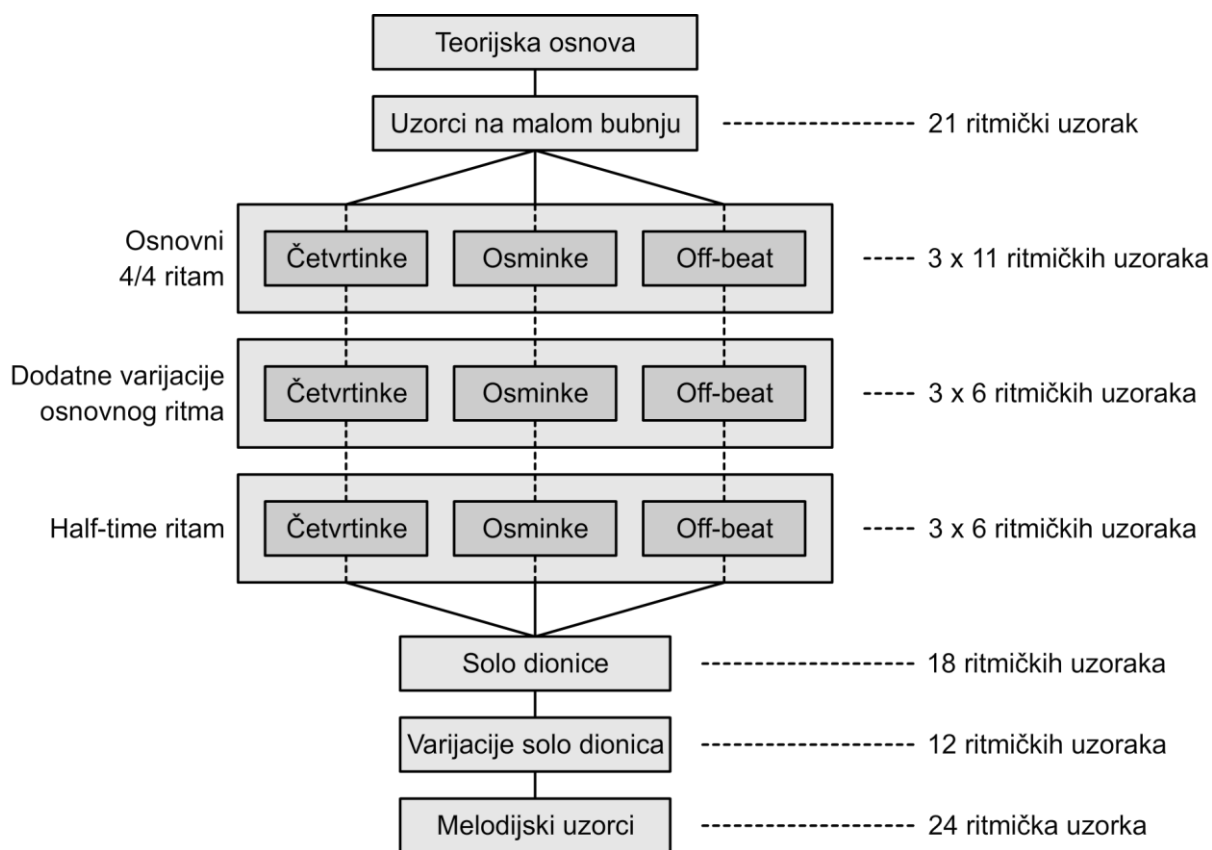
Glavni cilj prilikom korištenja ASPS-B-a je korisnika naučiti osnove sviranja seta bubnjeva. Korisnik bi nakon prolaska kroz bazu znanja trebao naučiti niz ritmičkih uzoraka koji se temelje na standardnom četvero četvrtinskom ritmu. Trebao bi savladati osnovnu tehniku sviranja seta bubnjeva te steći vještinu čitanja jednostavnijeg notnog zapisa za set bubnjeva.

Osnovno znanje u bazi znanja predstavljaju 144 ritmička uzorka koji su odabrani na temelju stručne literature i u suradnji s ekspertom (Fast Groove Builder, 2015). Uzorci koji sačinjavaju bazu znanja mogu se vidjeti u dodatku A. Kako bi se odredilo jasno predznanje koje je potrebno za svaki uzorak i jasni ishodi učenja prilikom učenja ritmičkih uzoraka, uzorci su podijeljeni u osnovnih 9 kategorija koje se međusobno nadovezuju jedna na drugu. Količina i izbor sadržaja se temelji na planiranoj provedbi evaluacije sustava. S obzirom da je

zamišljeno da svaki korisnik sustav testira/koristi deset školskih sati, količina materijala je prilagođena tom vremenu. Ritmički uzorci su podijeljeni u sljedeće kategorije:

1. Uzorci na malom bubnju (21 ritmički uzorak)
2. Osnovni ritam - četvrtinke (11 ritmičkih uzoraka)
3. Osnovni ritam - osminke (11 ritmičkih uzoraka)
4. Osnovni ritam - off-beat (11 ritmičkih uzoraka)
5. Dodatne varijacije osnovnog ritma (18 ritmičkih uzoraka)
6. Half-time ritam (18 ritmičkih uzoraka)
7. Solo dionice (18 ritmičkih uzoraka)
8. Varijacije solo dionica (12 ritmičkih uzoraka)
9. Melodijski uzorci (24 ritmička uzorka)


Slika 3.22. prikazuje na koji način su ove kategorije povezane. Na temelju tih veza definirano je potrebno prethodno znanje kako bi se krenulo u novu kategoriju. Iako znanje nije u svim slučajevima doslovno direktno povezano, neposredno, svaka sljedeća kategorija predstavlja ili nadogradnju znanja prethodne kategorije ili predstavlja kategoriju znanja koja je teža u odnosu na prethodnu.



Slika 3.22. Struktura ritmičkih uzoraka u bazi znanja

Prilikom izrade baze znanja, sustav su testirala dva korisnika zajedno s ekspertom kako bi se utvrdila prikladnost odabranih uzoraka. Najtežim dijelom pokazao se inicijalni prijelaz s vježbi na malom bubnju na sviranje osnovnih ritmova. Kako bi se olakšao taj prijelaz, broj uzoraka unutar kategorija osnovnih ritmova je nešto manji nego kod ostalih kategorija i iznosi 11 ritmičkih uzoraka. Nakon smanjivanja broja uzoraka unutar tih kategorija nije bilo generalno nekih većih problema sa savladavanjem tog sadržaja u predviđenom vremenskom razdoblju. Ostale kategorije su podjednake veličine stoga kod njih nije bilo nekih značajnijih vremenskih odstupanja. Jedino su zadnje dvije kategorije (varijacije solo dionica i melodijski uzorci) drugačije veličine jer kod tih kategorija ne postoji izravna veza "jedna kategorija jedan školski sat" već se varijacije solo dionica mogu savladati brže od ostalih kategorije jer imaju 6 uzoraka manje a melodijski uzorci imaju 6 uzoraka više u odnosu na ostale kategorije. Naravno, svaki korisnik će bazu prolaziti svojom brzinom u skladu sa svojim mogućnostima i sposobnostima. Količina sadržaja je prilagođena prosječnom korisniku.

Osim samih ritmičkih uzoraka, u bazi znanja se nalaze i dodatni nastavni materijali u obliku instrukcijskih video materijala. Za svaki ritmički uzorak snimljen je i video zapis gdje ekspert demonstrira kako ga ispravno odsvirati. Na slici 3.23. je prikazano kako izgleda prozor za demonstraciju sviranja ritmičkih zapisa. Putem kamere iznad seta bubnjeva korisnik može vidjeti cijeli set bubnjeva, jedino je za pedal bas snimljen dodatni kadar kako bi se lakše vidjelo kada treba udariti nogom pedal bas. Za svaki uzorak, snimljena su 4 takta sviranja.



Slika 3.23. Prozor za demonstraciju sviranja ritmičkog uzorka

Osim video materijala sviranja ritmičkih uzoraka, snimljeno je i dodatnih 19 video zapisa koji se pojavljuju na različitim mjestima tijekom prolaska baze znanja. Na početku se nalaze instrukcijski video materijali gdje se daju osnove o tome kako sjediti, držati palice i sl. Također, daje se osnovno znanje kako bi korisnik mogao početi čitati notni zapis. Kako se uvode složeniji uzorci, tako se objašnjava i nadograđuje to znanje. Svi video zapisi ukupno traju otprilike sat vremena. Neki od video zapisa su vrlo kratki i jednostavno daju motivacijsku poruku i uvod u ono što slijedi u narednim lekcijama. Na taj način se pokušava dodatno motivirati korisnika. S obzirom na to da korisnik uči putem korištenja računala, video materijali prikazuju eksperta koji predstavlja njihovog virtualnog tutora. Na taj način se želi nadomjestiti činjenica da korisnik nema pravog tutora.

3.4.3.2. Mehanizmi zaključivanja

Mehanizmi zaključivanja su odgovorni za temeljnu logiku funkcioniranja sustava. Svaka vrsta aktivnosti/lekcije ima svoje specifičnosti. Centralni dio sustava predstavlja aktivnost sviranja koja se temelji na konceptualnom modelu, tj. prilagodbi sadržaja lekcije potrebama i mogućnostima korisnika.

Kod svih interaktivnih vrsta aktivnosti koristi se interaktivno notno crtovlje putem kojeg korisnik vidi što i kada treba svirati. Notno crtovlje koristi standardnu notnu notaciju za sviranje perkusivnih instrumenata. Interaktivni dio predstavlja pomična crta koja korisniku daje do znanja gdje se vremenski nalazi u lekciji, tj. daje korisniku do znanja kada treba nešto odsvirati. Drugi interaktivni dio je vizualna povratna informacija o tome koja je nota točno odsvirana a koja nije. Prilikom sviranja točne note, preko note se pojavi zeleni kružić dok kada je nota krivo odsvirana, na notnom crtovlju se pojavi crveni znak "x".

Za detekciju točnosti sviranja, potrebno je odrediti parametar koliko korisnik može vremenski pogriješiti a da se još uvijek nota proglasi točno odsviranom. Čovjek ne može točno u milisekundu odsvirati traženu notu te svaka odsvirana nota odstupa od točno određenog vremena. Kako bi se odredilo dozvoljeno vremensko odstupanje, snimljeno je preko 200 ritmičkih uzoraka koje je odsvirao ekspert. Uzorci su svirani u točno određenom tempu (60 bpm) uz metronom te su snimljene MIDI informacije o preciznosti svake note. Prilikom sviranja, sve note nisu odsvirane dovoljno precizno. Nakon što je zapis snimljen, ekspert je preslušao snimljeni zapis te je označio one note za koje je smatrao da su odsvirane van tempa.

Preostale note su proglašene ispravno odsviranim notama. Izvršena je analiza točno odsviranih nota kako bi se utvrdio najveći dozvoljeni odmak a da se nota smatra točno odsviranom. Ritmički uzorci su se svirali brzinom 60 doba u minuti što znači da jedna doba traje jednu sekundu, odnosno 1.000 milisekundi. Najveći pomak među svim ispravno odsviranim notama iznosio je ± 125 milisekundi. Audio sučelje prilikom snimanja je imalo ulazno-izlaznu latenciju od 24 milisekunde stoga se može zaključiti kako je najveće dopušteno kašnjenje otprilike ± 100 milisekundi. Taj pomak se ne može uzimati apsolutno već se mora gledati relativno s obzirom na brzinu tempa što dovodi do zaključka da je dopušten odmak $\pm 10\%$ vremena trajanja jedne dobe, tj. iznosi $\pm 2,5\%$ trajanja jednog takta kod četvero četvrtinskog takta (Konecki, 2015c). Preciznija gradacija korisniku neće biti prikazana. Korisnik će jednostavno dobiti informaciju o tome je li nota točno odsvirana a detaljnija analiza vrši se kod kreiranja aktivnosti za ispravljanje učestalih grešaka. Teško je reći kako je točno podešen taj parametar kod drugih računalnih programa. Primjerice, igra Rockband u svojoj prvoj verziji je imala izuzetno malu toleranciju na grešku. U narednoj verziji igre su odlučili tu toleranciju povećati kako bi igra bila igrivija. Za računalne igre je vjerojatno prikladnije da igra bude igrivija te da ta tolerancija bude veća dok kod edukacijskih programa taj parametar bi trebao biti preciznije postavljen.



Slika 3.24. Vježbanje pojedinog ritmičkog uzorka

Kod aktivnosti vježbanja pojedinih ritmičkih uzoraka, nakon što se aktivira aktivnost, uzorak se ponavlja sve dok korisnik ne prestane svirati, tj. dok ne pusti da prođe jedan takt a da on nije ništa odsvirao. Nakon svakog odsviranog uzorka analizira se preciznost sviranja te se podatci o tome zapisuju u studentski model. Na sučelju pored interaktivnog notnog zapisa nalaze se još dva podatka: postotak naučenosti ritmičkog uzorka te podatak o tome koliko je uzoraka korisnik za redom odsvirao bez greške (slika 3.24.). Kako bi korisnik ostvario stopostotni uspjeh, potrebno je uzorak odsvirati 4 puta za redom bez greške. U bazi znanja se nalazi 144 uzorka unutar kojih se nalaze ukupno 1272 note. Prosječno gledano, to je 8,83 nota po uzorku. Kako bi korisnik odsvirao 4 takta bez greške, prosječno mora odsvirati 35 nota bez greške što je dovoljan broj kako bi statistički taj podatak bio relevantan.

Također, uzeto je u obzir vremensko ograničenje istraživanja koje se planira provesti a to je da će svaki korisnik sustav koristiti 10 školskih sati. U idealnim uvjetima kada korisnik ne bi napravio niti jednu grešku prilikom sviranja ritmičkog uzorka, potrebne su 24 sekunde za ostvarenje stopostotnog učinka: 4 sekunde za predtakt, 4 puta po 4 sekunde za sviranje uzoraka te na kraju 4 sekunde za prekid sviranja. Unutar svakog školskog sata korisnik bi trebao prosječno savladati petnaestak uzoraka (144 uzorka podijeljeno na 10 školskih sati). U idealnim uvjetima to bi iznosilo otprilike 6 minuta. Realno, korisnik će potrošiti mnogo više vremena kako bi naučio ritmičke uzorke, pogotovo na početku. Za učenje pojedinih ritmičkih uzoraka korisnik bi trebao potrošiti nešto više od 15 minuta školskog sata. Jednako tako, 20 minuta će mu biti potrebno za glavnu aktivnosti sviranja uzoraka pojedine kategorije i za aktivnost ponavljanja svega naučenog do sada. 5 minuta je predviđeno za prolazak aktivnosti ispravljanja učestalih grešaka. Preostalih 5 minuta korisnik će potrošiti na gledanje video zapisa i navigaciju sustavom. Ove vremenske vrijednosti predstavljaju zamišljenu putanju kroz sustav a svaki korisnik će naravno imati svoju dinamiku a moguća su čak i veća odstupanja od zamišljenog plana, sve ovisi o mogućnostima i sposobnostima korisnika.

Centralni dio aplikacije je aktivnost sviranja koja se temelji na kreiranom konceptualnom modelu prilagodbe korisniku (slika 3.4.). Za svaku kategoriju ritmičkih uzoraka postoji aktivnost sviranja unutar koje se sviraju ritmički uzorci te kategorije. Ona se dinamički generira te je svaki put drugačija. Na početku, dok su svi uzorci unutar kategorije nenaučeni, aktivnost započinje s generiranjem početnih 8 taktova vježbe (slika 3.25.). Ti taktovi su odabrani nasumično između 5 početnih (najlakših) ritmičkih uzoraka unutar kategorije.



Slika 3.25. 8 taktova vježbe sviranja

Uzorci u kategoriji se na početku dijele u 3 skupa uzoraka:

1. naučeni uzorci (na početku prazan skup),
2. uzorci koji se uče (trenutno aktivni, na početku početnih 5 uzoraka) i
3. nenaučeni uzorci (svi ostali uzorci).

Nakon svakog odsviranog uzorka, analizira se uspješnost sviranja tog uzorka te se ažurira studentski model. Za svaki uzorak pamti se s kojim postotkom uspješnosti je korisnik odsvirao zadnja 4 sviranja tog uzorka. Na temelju postotka uspješnosti sviranja ritmičkih uzoraka lekcija sviranja se generira u stvarnom vremenu.

Kada se jedan od ritmičkih uzoraka nauči s 80% uspješnosti, tada se iz skupa nenaučenih uzoraka jedan novi uzorak dodaje u skup uzoraka koji se uče. Tek kada se uzorak nauči sa 100% preciznošću, tada se prebacuje u skup naučenih uzoraka. U slučaju da je postotak sviranja nekog uzorka manji od 40% nakon što je četiri puta odsviran, tada se taj uzorak vraća u skup nenaučenih uzoraka te će se kasnije ponovno vratiti u skup uzoraka koji se uče. Iako su uzorci otprilike poredani po težini unutar kategorije, može se dogoditi da je neki uzorak nekom u određenom trenutku pretežak. U tom slučaju taj uzorak se izbacuje te će se kasnije vratiti, dok korisnik još provježba neke druge uzorke unutar kategorije.

Prilikom ove mehanike bilo je potrebno odrediti postotke za uvođenje novih uzoraka (80%) te postotak za izbacivanje uzorka (40%) koji će se učiti kasnije. Kako bi se oni odredili, ekspert je testirao ovu vrstu aktivnosti s različitim parametrima. Ako je postotak za uvođenje novih uzoraka bio premalen, tada su vrlo brzo svi uzorci ušli u skup uzoraka koji se uče te se vježba pretvorila u nasumično generiranje svih uzoraka određene kategorije. S druge strane, ako se taj uzorak postavi izuzetno visoko, tada lekcija postaje relativno linearna i neprestano je u opticaju svega nekoliko uzoraka. Kada jedan uzorak biva naučen, tako novi ulazi u skup uzoraka koji se uče. Nakon dvadesetak iteracija parametriziranja, odlučeno je da taj postotak bude 80% jer predstavlja neki balans između linearnosti i potpune nasumičnosti. Jednako tako provedeno je testiranje za postotak izbacivanja uzorka. Kada bi taj postotak bio previsok, tada bi se uzorci prečesto vraćali u skup nenaučenih uzoraka te bi se opet dobila relativno velika nasumičnost. Jednako tako, kada bi bio premalen tada ne bi bilo moguće izbaciti uzorak. Taj postotak je tako određen da samo izuzetno teški uzorci bivaju izbačeni kako bi se učili kasnije.

U donjem desnom dijelu sučelja nalaze se dva podatka: ukupna uspješnost naučenosti svih uzoraka unutar kategorije te broj koliko uzoraka je do sada u potpunosti naučeno, tj. naučeno sa stopostotnim uspjehom. Osim sumarne informacije, u donjem lijevom dijelu sučelja korisnik može vidjeti i vizualno koji uzorci su naučeni a koji su u procesu učenja. Slika 3.26. prikazuje taj dio sučelja.

1	2	3	4	5
6	7	8	9	10
11	12	13	14	15
16	17	18		

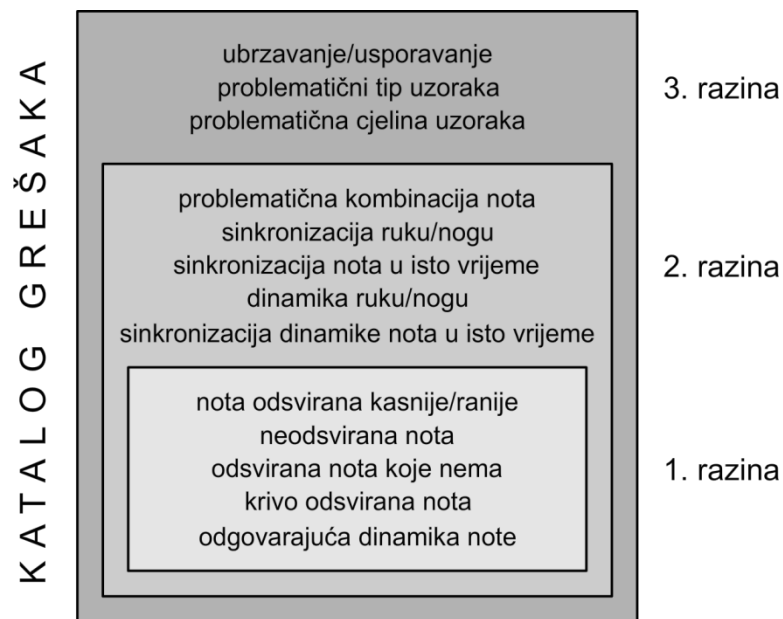
Slika 3.26. Naučenost pojedinih ritmičkih uzoraka unutar kategorije

Na temelju ovih informacija korisnik može sam vidjeti koji su to uzorci koje treba eventualno dodatno provježbati nakon čega bi aktivnost sviranja mogao riješiti sa stopostotnim učinkom. Naravno, korisnik ne mora na svim aktivnostima ostvariti maksimalan uspjeh. Većina korisnika sustava su u istraživanju ili ostvarili stopostotni uspjeh ili su bili vrlo blizu.

Generiranje lekcije se vizualno izvršava tako da bude što manje upadljivo korisniku. Kada korisnik u sviranju dođe do sredine drugog reda (odsvirana 2 takta drugog reda), tada se note u prvom redu brišu te se generiraju nova 4 takta. Jednako tako, kada korisnik dođe u prvi red, nakon 2 odsvirana takta, note drugog reda se brišu te se ubacuju novi uzorci. To se događa u trenutku između sviranja dva takta. Kao što je već napomenuto, lekcija se generira sve dok korisnik ne prestane svirati. Kada korisnik nauči sve uzorke iz kategorije, lekcija se i dalje može svirati te se tada nasumično generiraju svi uzorci koji se nalaze u toj kategoriji.

Lekcija ponavljanja je za razliku od lekcije sviranja fiksne dužine i onda traje 32 takta. Lekcija se u potpunosti generira prije samog početka sviranja no također se generira dinamički i svaki put je drugačija. S obzirom na to da se lekcija ponavljanja nalazi nakon svake kategorije ritmičkih uzoraka, onda je generiranje uzoraka unutar te lekcije složeno tako da se prilikom generiranja lekcije u nju ubaci minimalno 20% uzoraka iz zadnje kategorije ritmičkih uzoraka koja se učila. Maksimalan postotak nije određen već je varijabilan. Na taj način se vježbaju svi dosadašnji uzorci s naglaskom na uzorke zadnje učene kategorije.

Aktivnost za otklanjanje učestalih grešaka je aktivnost čije je pojavljivanje dinamičko te ovisi o količini i vrsti grešaka koje korisnik radi. U slučaju da korisnik ne radi učestalo greške određenog tipa, tada korisniku ova aktivnost neće biti dostupna jer se ona generira u specifičnim slučajevima kada je to potrebno. U katalogu grešaka su definirane greške koje sustav može detektirati. Slika 3.27. prikazuje vrste grešaka koje sustav može detektirati te njihovu klasifikaciju.



Slika 3.27. Katalog grešaka, klasifikacija grešaka

Na najnižoj razini (1. razina) nalaze se jednostavne greške koje se temelje na pojedinim notama. Većina ovih grešaka je vidljiva korisniku kroz interaktivno notno crtovlje i povratnu informaciju koju dobiva. Korisnik može vidjeti je li neku notu odsvirao prerano ili prekasno. Sustav detektira također kada je neka nota neodsvirana. U prvoj verziji sustava se i ta informacija korisniku prikazala u obliku žutog "x" znaka no kroz daljnje testiranje se pokazalo da je ta informacija dodatni vizualni teret koji nije bio od velike važnosti. Već kroz postojeće vizualne povratne informacije korisnici su jasno mogli vidjeti ako su zaboravili odsvirati neku notu. Sustav također prepoznaje događaj kada korisnik odsvira notu a nota nije trebala biti odsvirana ili kada nota postoji no umjesto nje je odsvirana neka druga nota. Osim grešaka dinamike pojedine note, ostale greške korisnik jasno može i sam percipirati kroz dobivene povratne informacije. Korisnici na ove vrste grešaka u pravilu reagiraju odmah jer ih prepoznaju zbog povratnih informacija (osim dinamike).


Druga razina temelji se na detekciji grešaka prve razine a predstavlja greške koje se temelje na više nota koje treba odsvirati u isto vrijeme. Kada se odsvira neka nota koja nije bila odsvirana, korisnik dobiva o tome povratnu informaciju. No kako bi se otkrio razlog zašto se to dogodilo, potrebno je analizirati kontekst. Primjerice, slika 3.28. prikazuje jednu vrstu greške koja se često zna dešavati kod početnika a to je situacija kada desna ruka prati ono što radi desna noga. Ako se uoči učestalost pojave greške u tom kontekstu, tada se može

zaključiti da korisnik ima s tim problema te mu se na to može svratiti pažnja (Konecki, 2015c).



Slika 3.28. Desna ruka prati desnu nogu

Jednako tako se može uočiti problem sinkronizacije određene kombinacije ruku i nogu. Za svaku notu se zna da li treba biti odsvirana lijevom ili desnom rukom i naravno pedal bas se svira desnom nogom. Ako se uoči da su kod određene kombinacije greške učestalije, tada se to može istaknuti korisniku. Što se tiče sinkronizacije nota koje se trebaju odsvirati u isto vrijeme, ono što se može dogoditi je da su obje note same za sebe odsvirane točno no da međusobno nisu sinkronizirane. Primjerice, ukoliko je u isto vrijeme potrebno odsvirati mali bubanj i pedal bas. Ekstremni primjer bi bio da je mali bubanj odsviran 100 milisekundi ranije od potrebnog trenutka dok je pedal bas odsviran 100 milisekundi kasnije od traženog. Obje note bi bile proglašene točne no između njih bi bila veća razlika od 100 milisekundi. Gledanjem vremenske razlike između nota koje trebaju biti odsvirane u isto vrijeme moguće je uočiti ovakve greške. Također, razlika u dinamici sviranja se može promatrati u kontekstu. Primjerice, ono što se može dogoditi je da desna ruka koja svira hihat u trenutku kada s lijevom rukom treba udariti u mali bubanj jače udara hihat (Konecki, 2015c). Slika 3.28. prikazuje taj scenarij.



Slika 3.29. Dinamika sviranja hihat činele

Na trećoj razini nalaze se greške koje se temelje na još širem kontekstu. Ubrzavanje ili usporavanje se može promatrati na razini pojedinog uzorka ili čak šire od toga. Računanjem

relativne vremenske razlike između udaraca unutar takta može se izračunati odmak u tempu od tempa koji je zadan. Jednostavniji način je detekcija učestalog preranog ili prekasnog sviranja nota unutar uzorka. Jednako tako može se dogoditi da postoji određeni skup uzoraka s kojim korisnik ima više problema. Ili cijela kategorija uzoraka predstavlja veći problem korisniku. Primjerice, u uzorcima solo dionica uvode se novi elementi sviranja pa korisniku to može predstavljati dodatne probleme. Kada se uoči statistička razlika u razlici uspješnosti sviranja tada se može korisnika usmjeriti na taj problem. Slika 3.30. prikazuje osnovnu klasifikaciju ritmičkih uzoraka koji se nalaze u bazi znanja (Konecki, 2015c).



Slika 3.30. Klasifikacija uzoraka baze znanja

Csikszentmihalyi ističe kako nije dobro korisnika usmjeravati na mnogo grešaka koje čini (Csikszentmihalyi, 1990). Bolji pristup je usmjeriti se samo na jednu grešku koja je najučestalija a onda u nekim drugim iteracijama vidjeti koje greške su najučestalije. Na taj način je implementirano generiranje aktivnosti za otklanjanje učestalih grešaka u ASPS-B-u. Što se tiče određivanja prioriteta grešaka, razina 3 ima najveći prioritet jer se temelji na najvećem broju nota. Slijedno, razina dva se uglavnom temelji na dvije note te ona ima sljedeći prioritet te na kraju. Unutar razine se gleda koja vrsta grešaka je najučestalija. Kada se odredi vrsta greške, tada se generira aktivnost koja je slična aktivnosti ponavljanja: fiksne je dužine i sadrži uzorke u kojima se pojavljuju situacije kod kojih je korisnik činio odabrani tip greške.

3.4.4. Studentski model

U studentskom modelu zapisuju se sve važne informacije o korištenju sustava i korisnikovom napretku sviranja. Na temelju ovih informacija sustav prati proces učenja korisnika te na temelju tih informacija sustav generira lekcije koje su prilagođene korisniku koje se temelje na statističkim podacima o njegovom trenutnom znanju. Studentski model se neprestano ažurira: prilikom navigiranja kroz sustav te za vrijeme sviranja lekcija.

Prilikom kreiranja profila korisnika, za svakog korisnika se kreira posebna datoteka u kojoj će biti zapisani njegovi podaci. Ta datoteka ostaje trajno sačuvana na računalu sve dok korisnik koristi sustav, tj. sve dok se njegov profil ne resetira ili obriše.

Za svakog korisnika pamti se oko dvije tisuće numeričkih vrijednosti unutar nekoliko kategorija podataka:

- podaci o pristupu različitim aktivnostima (176)
- podaci o tome kojim video zapisima se pristupilo (161)
- statistički podaci o uspješnosti sviranja pojedinog uzorka (864)
- statistički podaci o uspješnosti sviranja uzoraka u kontekstu (864)
- podaci o sumarnoj uspješnosti sviranja aktivnosti sviranja i ponavljanja (15)

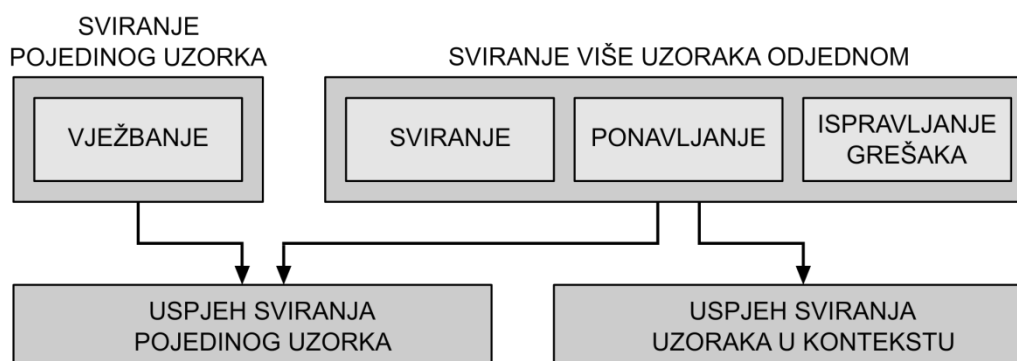
Kako bi korisnik mogao bolje pratiti svoj napredak kroz lekcije koje su mu dostupne, kroz korisničku sučelje korisnik može vidjeti koje aktivnosti je do sada izvršio. U glavnom izborniku lekcija korisniku je dostupno 17 video lekcija, 144 lekcija vježbanja pojedinih ritmičkih uzoraka, 9 aktivnosti sviranja (za svaku pojedinu kategoriju uzoraka) te 6 aktivnosti ponavljanja. Nakon prve kategorije nije potrebna lekcija ponavljanja jer bi ona bila identična završnoj vježbi sviranja. Prva vježba ponavljanja se pojavljuje tek nakon što korisnik prođe više kategorija jer se u vježbi ponavljanja kombiniraju ritmički uzorci različitih kategorija.

Također, korisnik može pratiti koje je sve video materijale pogledao. Osim 17 aktivnosti u obliku video zapisa, svaka aktivnost vježbanja pojedinog ritmičkog uzorka u sebi sadrži i video zapis gdje korisnik može vidjeti kako ispravno odsvirati odabrani ritmički uzorak. Iako ova informacija nije od velike važnosti jer korisnik obično gleda ove video zapise samo kada mu je to potrebno, korisnik može vidjeti kod kojih ritmičkih uzoraka je pogledao instrukcijski video. Kada korisnik neki ritmički uzorak savlada sa stopostotnim uspjehom, bez obzira da li je pogledao instrukcijski video ili ne, dobiva zlatni rub za tu aktivnost koji označava da je uspješno obavio sve vezano za tu aktivnost. Glavni cilj je da korisnik nauči svirati ritmičke uzorke a ne da nužno pogleda sve video zapise koji se nalaze u sustavu.

Kako bi korisnik mogao pratiti koje je pojedine ritmičke uzorke naučio, za svaki ritmički uzorak pamte se statistički podaci o uspješnosti sviranja tog uzorka. Za svaki uzorak pamte se

zadnja 4 sviranja tog uzorka te se u obliku postotka taj podatak zapisuje u studentskom modelu. Postotak se računa tako da se ispravno odsvirane note podjele s ukupnim brojem nota u uzorku. Također, u modelu se pamti indeks zadnje sviranog uzorka te se podatci ciklično prepisuju kako korisnik nastavlja sa sviranjem pojedinog uzorka. Na početku su svi postotci na nuli te kako bi korisnik za pojedini uzorak postigao stopostotnu uspješnost sviranja, potrebno je 4 puta za redom uzorak odsvirati bez greške. Također, u studentskom modelu pamti se i sumarni postotak za svaki pojedini ritmički uzorak te se taj postotak koristi za generiranje i prilagodbu narednih lekcija. Sumarni postotak se računa tako da se zbroje postotci uspješnosti za zadnja 4 sviranja uzorka te se njihov zbroj podijeli s četiri.

Osim postotka uspješnosti sviranja svakog pojedinog uzorka, prate se i posebni podatci o sviranju tih istih uzoraka u kontekstu lekcija za sviranje i lekcija ponavljanja. S obzirom da nije isto vježbati svaki pojedini uzorak posebno i svirati ga u kontekstu ostalih uzoraka kategorije ili u kontekstu svih ritmičkih uzoraka koji se nalaze u bazi znanja, posebno se prati statistika uspješnosti sviranja ritmičkih uzoraka u kontekstu sviranja i ponavljanja. Svirati ritmičke uzorke koji se izmjenjuju, bilo unutar kategorije ili izvan, je zasigurno teže nego vježbati pojedini uzorak. Sviranjem pojedinih uzoraka, u studentskom modelu se ažuriraju postotci za praćenje sviranja pojedinih uzoraka. No prilikom sviranja ritmičkih uzoraka u kontekstu, u studentskom modelu se ažuriraju i postotci sviranja u kontekstu i postotci sviranja pojedinih uzoraka. Ako korisnik u kontekstu uspije uspješno odsvirati uzorke tada će ih sigurno moći uspješno i pojedinačno odsvirati jer je znanje pojedinačnog sviranja zapravo podskup kontekstualnog sviranja. Slika 3.31. prikazuje način na koji se ažuriraju postotci u studentskom modelu.



Slika 3.31. Ažuriranje studentskog modela za različite aktivnosti

Osim postotaka za pojedine ritmičke uzorke, za aktivnosti sviranja i ponavljanja pamte se i sumarni postotci za izvršavanje tih aktivnosti. U sustavu postoji 9 glavnih aktivnosti sviranja i

6 aktivnosti ponavljanja. Ove informacije se također prikazuju korisniku u glavnom izborniku lekcija kako bi mogao pratiti svoj napredak u prolasku kroz lekcije.

Podatci o greškama koji se koriste za generiranje vježbi za otklanjanje najučestalijih grešaka se ne zapisuju trajno u studentskom modelu. Ovi podatci postoje unutar sustava za vrijeme korištenja sustava. Nakon što korisnik prestane koristiti sustav, ti podatci se brišu kako se ne bi desilo da na temelju zastarjelih podataka sustav kreira vježbu otklanjanja neke greške. Na ovaj način lekcije za otklanjanje grešaka generiraju se samo na temelju aktualnih podataka koji su neposredno nastali prilikom zadnjeg vježbanja.

3.4.5. Instrukcijski model

U instrukcijskom modelu se definiraju načini poučavanja i načini prolaska kroz bazu znanja. Csikszentmihalyi ističe u svojoj teoriji protoka da je važno usmjeravati korisnika u procesu učenja no također je važno da korisnik ima osjećaj slobode, da sam može birati aktivnosti koje će prolaziti te da se sam može usmjeravati u procesu učenja (Csikszentmihalyi, 1997). U ASPS-B-u u glavnom izborniku lekcija korisniku se sugerira put kojim bi trebao prolaziti lekcije no korisnik sam odabire da li će pratiti predloženi put ili će na svoj način prolaziti lekcije.

Kao što je već spomenuto, u sustavu postoji 5 temeljnih tipova lekcija, tj. aktivnosti:

- Instrukcijski video materijali
- Vježbanje pojedinog ritmičkog uzorka
- Sviranje uzoraka određene kategorije
- Ponavljanje svih uzoraka koji su do sada učeni
- Aktivnost za ispravljanje učestalih grešaka

Instrukcijskim video materijala ima svega nekoliko. Video materijali su iskorišteni kako bi se korisniku dalo osnovno znanje koje je potrebno kako bi mogao početi sa sviranjem prvih praktičnih lekcija. Glavna ideja je da učenje bude što više aktivno a što manje pasivno. Osim aktivnosti gledanja video materijala, sve ostale aktivnosti zahtijevaju da korisnik radi nešto praktično.

U instrukcijski dio sustava također ulazi vježbanje pojedinog ritmičkog uzorka. Ove aktivnosti su zamišljene kao početne točke za učenje uzoraka svake pojedine kategorije. Također se mogu koristiti i u drugom kontekstu: nakon što korisnik prilikom sviranja ritmičkih uzoraka pojedine kategorije detektira uzorke koji mu stvaraju problem, putem ovih aktivnosti ih može dodatno provježbati.

Aktivnost sviranja je centralna vrsta aktivnosti gdje se sviraju uzorci koji su grupirani u odgovarajuće kategorije. Lekcije se prilagođavaju korisniku te kroz prilagodbu korisnik može optimizirati potrošeno vrijeme za savladavanje određene grupacije ritmičkih uzoraka. Jednako tako, aktivnost ponavljanja se nadovezuje na aktivnost sviranja. U toj aktivnosti korisnik svira sve ritmičke uzorke koje je do sada naučio i na taj način uči kombinirati sve uzorke koji se nalaze u bazi znanja i time se kompletira svo znanje u jednu cjelinu. Posebna aktivnost za ispravljanja grešaka se pojavljuje u specifičnim trenutcima kada se prepozna da korisnik ima problema s određenim specifičnim tipom grešaka. Većinu grešaka koje korisnik čini može i sam prepoznati kroz neposredne povratne informacije koje su mu dostupne no neke vrste grešaka korisnik neće uspjeti prepoznati ili za određene vrste grešaka ne postoji neposredna povratna informacija (primjerice za dinamiku sviranja).

Postoji nekoliko tipičnih scenarija kako korisnik može izvršavati lekcije koje su mu dostupne. Većina korisnika će pratiti predloženi put prolaska kroz bazu znanja tako da će pogledati početne instrukcijske video materijale te će započeti vježbanje pojedinih ritmičkih uzoraka. Nakon što prođe sve aktivnosti sviranja pojedinih ritmičkih uzoraka, tada će prijeći na vježbu gdje se svi ti uzorci sviraju zajedno. Također će prolaziti kategoriju po kategoriju uzoraka. Nakon svake kategorije izvršit će i aktivnost ponavljanja gdje će se kombinirati svi uzorci iz svih kategorija koje je do sada naučio.

Prilikom sviranja pojedinih ritmičkih uzoraka neki će prvo sve pojedinačne uzorke naučiti sa stopostotnim uspjehom i tek tada krenuti na težu vježbu gdje sve te uzorke trebaju svirati zajedno. Drugi će pak proći pojedinačne uzorke tek toliko da znaju kako ih ispravno odsvirati i neće se zamarati s postotkom već će ranije krenuti na aktivnost sviranja svih uzoraka zajedno. Određeni korisnici sustava su kod kasnijih kategorija odmah išli na aktivnost sviranja jer im je bilo zanimljivije i izazovnije odmah pokušati svirati cijelu kategoriju uzoraka bez vježbanja pojedinih uzoraka. Različiti korisnici će na različite načine prolaziti kroz bazu znanja, ovisno o percepciji težine uzoraka i percepciji njihove vještine sviranja.

4. EVALUACIJA MODELA I PROTOTIPA

Iako je iz pregleda znanstvene literature vidljivo da postoji nekoliko razvijenih alata za poučavanje sviranja raznih glazbenih instrumenata, ono što kod njih nedostaje je kvalitetna evaluacija. Primjerice, Violin Tutor je testiran na svega 12 korisnika: tri djeteta, tri roditelja, tri početnika, dva napredna svirača i jedan učitelj (Yin et al., 2005). Na IMUTUS projektu je provedeno istraživanje na 12 učenika gdje je pola učenika koristilo kreirani sustav a druga polovica je sačinjavala kontrolnu grupu (Raptis, 2006). Piano Tutor je testiralo 18 korisnika od kojih je testiranje završilo svega njih deset (Dannenberg et al., 1993). Na najvećem projektu, iMaestro, nikada nije izvršen proces evaluacije sustava. Jednako tako nije evaluiran ni pianoFORTE iako su autori najavili da su započeli s procesom evaluacije (Smoliar, 1995).

Kako bi se postavljene hipoteze potvrdile ili opovrgnule, potrebno je provesti adekvatnu evaluaciju. Novokreirani konceptualni model je uspoređen s alternativnim samostalnim metodama učenja sviranja seta bubnjeva kako bi se utvrdilo postoji li statistički značajna razlika u motivaciji i kvaliteti naučenog znanja, odnosno vještine sviranja, između polaznika različitih grupa poučavanja.

Kako bi se izvršila valjana evaluacija konceptualnog modela (i prototipa sustava), u samom istraživanju sudjelovalo je 90 korisnika koji su ravnomjerno raspoređeni u 3 grupe te time čine prigodan uzorak korisnika za svaku grupu. Korisnici koji su birani u grupe nisu imali prijašnja znanja niti iskustvo sviranja seta bubnjeva. U istraživanju su definirane sljedeće ispitne grupe:

1. Korisnici koji će koristiti kreirani prototip
2. Korisnici koji će koristiti alternativni računalni program, HD-1 Drum Tutor
3. Korisnici koji će učiti uz pomoć video poduka te drugih multimedijских sadržaja

Sve tri grupe koristile su Rolandove električne bubnjeve prilikom učenja sviranja. Također, sve tri grupe su koristile istu bazu znanja prilikom učenja (ispis uzoraka iz baze znanja nalazi se u prilogu A). Ono što je različito od grupe do grupe je metoda samostalnog učenja sviranja seta bubnjeva.

Prva grupa je učila svirati set bubnjeva putem kreiranog prototipa koji se bazira na opisanom konceptualnom modelu. Unutar sustava korišteni su kreirani video materijali kao i opisana baza znanja. Aktivnost "jam session" u kojoj se uče pojedini uzorci određene kategorije uzoraka se prilagođava korisničkom sviranju, kao i vježba "sve do sada", već prema opisanim pravilima. Također, sustav je u mogućnosti detektirati određene uzorke u vrsti grešaka i tada korisniku omogućiti aktivnost putem koje može korisnika usmjeriti na one aspekte sviranja koje je nužno ispraviti.

Druga grupa je koristila iste video materijale i istu bazu znanja u procesu učenja no korisnici ove kontrolne grupe su uzorke učili svirati putem računalnog programa Roland HD-1 Drum Tutor (DT-1, 2015). Razlika u odnosu na prvu grupu je ta da u Rolandovom softveru ne postoji prilagodba materijala korisniku stoga se vježbe "jam session" i "sve do sada" ne generiraju već se sastoje od određenog seta uzoraka. "Jam session" se sastoji od nasumično odabranih uzoraka iz pojedine kategorije dok vježbe tipa "sve do sada" sadrže nasumično odabrane uzorke od svih uzoraka koji su se učili do trenutka dolaska te vježbe. Aktivnosti "jam session" i "sve do sada" se kao i kod prve grupe nalaze nakon svake kategorije uzoraka. Korisnici ove metode učenja, baš kao i korisnici prve grupe, imaju izravnu povratnu informaciju tokom učenja sviranja o točnosti osviranih nota. To je karakteristika koja je prvoj i drugoj grupi zajednička dok se grupe razlikuju u vježbama "jam session" i "sve do sada": kod prve grupe vježba se prilagođava karakteristikama sviranja korisnika dok to svojstvo ne postoji kod druge grupe.

Treća grupa je grupa koja nije koristila nikakav dodatni računalni softver prilikom učenja sviranja seta bubnjeva, koristila je isključivo materijale u video obliku te pisane materijale u notnom zapisu. Jedino pomagalo koje je treća grupa koristila metronom koji se nalazi na električnim bubnjevima. Ova grupa predstavlja najtipičniji samostalni način učenja sviranja bubnjeva: korisnik koristi video materijale (preuzete na internetu ili kupljene) kako bi naučio svirati i onda samostalno pokušava reproducirati naučeno. Putem video zapisa korisnik može vidjeti kako odsvirati svaki pojedini ritmički uzorak te uči neke osnovne teoretske sadržaje (pravilno držanje, interpretacija notna i sl.). U pisanim materijalima nalaze se pojedini ritmički uzorci te iste "jam session" i "sve do sada" vježbe, kao i kod prijašnjih grupa. Razlika ove kontrolne grupe u odnosu na prijašnje grupe je u tome što prilikom učenja sviranja ne postoji izravna povratna informacija o točnosti sviranja od strane sustava/računala već se korisnik oslanja na svoju vlastitu procjenu.

Korisnici svih grupa su samostalno učili svirati set bubnjeva određenom metodom 10 školskih sati te su prilikom toga vodili evidenciju o tome što su koji sat radili (primjeri evidencije u prilogu E). Iako su prikupljeni, ovi podatci nisu korišteni u potvrđivanju ili opovrgavanju definiranih hipoteza no ti podatci bi mogli poslužiti za dodatne spoznaje o načinima kako su korisnici prolazili kroz bazu znanja određenim metodama samostalnog učenja i postoji li neki karakteristični načini prolaska a da su povezani s metodom učenja sviranja seta bubnjeva.

4.1. Određivanje uniformnih grupa ispitanika

Na početku evaluacijskog procesa, u suradnji s ekspertom, odabrano je 15 ritmičkih uzoraka koji su poslužili za određivanje inicijalne sposobnosti korisnika. Uzorci su poredani otprilike po težini. Kreću se od jednostavnog uzorka putem kojeg se testira ima li korisnik osjećaj za ritam sve do relativno zahtjevnih uzoraka.

Način evaluacije se provodio na sljedeći način: ekspert je udaranjem rukom po stolu odsvirao ritmički uzorak a korisnik ga je nakon toga trebao ponoviti. Nakon svakog odsviranog uzorka bilježilo se je li korisnik ispravno replicirao uzorak eksperta. Jednostavnim zbrajanjem koliko je točnih uzoraka odsvirano, napravljena je inicijalna procjena sposobnosti korisnika. Na slici 4.1. mogu se vidjeti uzorci koji su korišteni za inicijalnu evaluaciju korisnika.



Slika 4.1. Uzorci za inicijalnu procjenu sposobnosti korisnika

S obzirom na to da je istraživanje bilo provođeno u vremenskom periodu od godinu dana na različitim lokacijama, kreirani su uređeni parovi korisnika za svaku od grupa. Ukoliko su u inicijalnoj evaluaciji postojala 3 korisnika koja su ostvarila jednaki broj točno odsviranih

uzoraka, tada je po jedan korisnik dodijeljen svakoj od grupa. Na taj način su kreirane grupe koje bi trebale biti prema inicijalnoj sposobnosti sviranja jednake.

Broj točno odsviranih uzoraka kod sudionika istraživanja varira od 9 do 14. Prema broju točno odsviranih uzoraka, svaka grupa sastojala se od:

- 4 učenika koji su odsvirali 9 točnih uzoraka,
- 5 učenika koji su odsvirali 10 točnih uzoraka,
- 6 učenika koji su odsvirali 11 točnih uzoraka,
- 7 učenika koji su odsvirali 12 točnih uzoraka,
- 5 učenika koji su odsvirali 13 točnih uzoraka, te
- 3 učenika koji su odsvirali 14 točnih uzoraka.

Niti jedan učenik nije uspio odsvirati svih 15 uzoraka bez greške. Prema dobivenoj distribuciji čini se da su uzorci bili prikladne težine te da su kreirane podjednake grupe za istraživanje. U istraživanju su ravnomjerno zastupljeni učenici oba spola te su svi bili srednjoškolskog uzrasta (učenici od prvog do trećeg razreda srednje škole).

4.2. Proces evaluacije samostalnih metoda učenja sviranja seta bubnjeva

Proces evaluacije samostalnih metoda učenja sviranja seta bubnjeva provodio se na nekoliko različitih lokacija u vremenskom periodu od godine dana. Kao što je već rečeno, svaki učenik učio je svirati set bubnjeva odabranom metodom 10 školskih sati. Najčešće su učenici svirali po jedan školski sat svakog dana te su u periodu od dva tjedna (sviranje od ponedjeljka do petka) odradili 10 školskih sati sviranja. Nakon zadnjeg termina, učenici su pristupili sviranju završne vježbe na temelju koje se radila evaluacija o tome koliko su učenici uspješno naučili svirati set bubnjeva.

Završna vježba je dizajniranja u suradnji s ekspertom a sastoji se od pomno odabranih 60 uzoraka iz ukupnog skupa od 144 ritmička uzorka iz baze znanja. Svaka kategorija uzoraka je podjednako zastupljena u završnoj vježbi. Ritmički uzorci iz svih kategorija su kombinirani s uzorcima solo dionica a na kraju same vježbe nalaze se najteži uzorci (melodijski uzorci). Trajanje sviranja završne vježbe u predviđenom tempu od 60bpm je točno 4 minute što je otprilike dužina trajanja jedne prosječne komercijalne pjesme. Kada bi korisnik u završnoj

vježbi trebao odsvirati sve uzorke u nizu, jedan za drugim, to bi trajalo gotovo 10 minuta i to bi vremenski bilo predugo za početnike koji tek 10 školskih sati uče svirati glazbeni instrument. Zadržati koncentraciju tako dugo bilo bi zbilja izazovno stoga je vrijeme trajanja završne vježbe skraćeno na 4 minute. Uzorci završne vježbe se nalaze u prilogu.

Svi sudionici istraživanja su svirali istu završnu vježbu kako bi se mogla napraviti izravna usporedba uspješnosti sviranja svakog pojedinog sudionika. Tijekom sviranja završne vježbe mjerilo se koliko je uzoraka točno odsvirano te se također mjerilo koliko je sveukupno točnih nota odsvirano. Na temelju tih numeričkih vrijednosti napravljena je usporedba kako bi se pokazalo da li se određenom metodom učenja u prosjeku postižu bolji rezultati u odnosu na drugu metodu učenja. Završna vježba se također snimala u audio formatu kako bi na temelju audio snimke ekspert mogao ocijeniti svakog pojedinog sudionika istraživanja. Nakon što su svi sudionici odsvirali završne vježbe, svi audio zapisi završnih vježbi su jednostavno numerirani brojevima od 1 do 90 te su predani ekspertu na ocjenjivanje. Ekspert nije znao kojoj grupi pripada pojedini audio zapis niti kojem sudioniku.

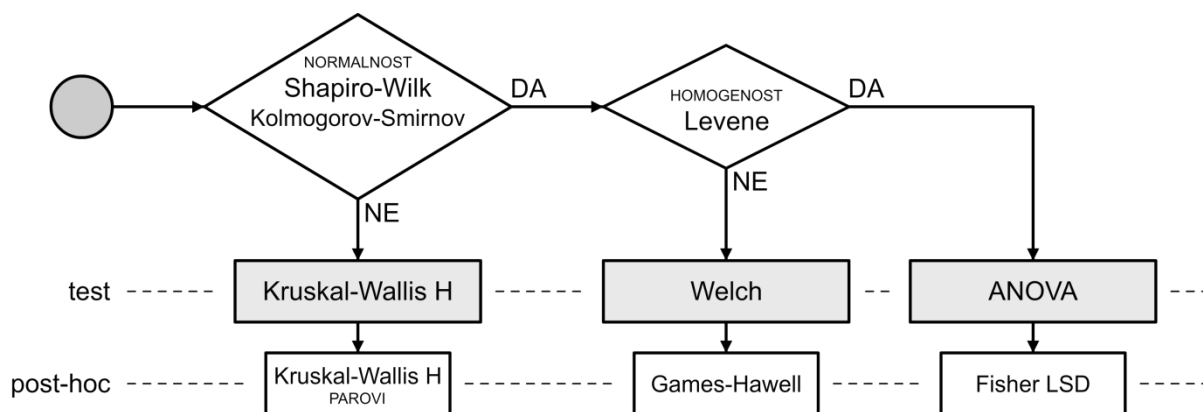
Neposredno nakon sviranja završne vježbe, sudionici istraživanja su ispunili dva anketna upitnika putem kojih se izmjerila njihova percepcija o njihovoj intrinzičnoj motivaciji te stanju protoka prema Csikszentmihalyijevoj teoriji. Prvi anketni upitnik za mjerenje percepcije o intrinzičnoj motivaciji je standardizirani upitnik koji se temelji na teoriji samoodređenja te je preuzet sa službenih internetskih stranica navedene teorije (Deci & Ryan, 2011; Self-determination theory, 2015). Drugi anketni upitnik je također standardizirani anketni upitnik koji se bazira na Csikszentmihalyijevoj teoriji stanja protoka (Jackson & Marsh, 1996). Analizom rezultata ovih anketnih upitnika utvrdilo se postoji li statistički značajna razlika u percepciji motivacije sudionika između eksperimentalne grupe i kontrolnih grupa. Anketni upitnici se nalaze u prilogu.

S obzirom na to da su sve mjere putem kojih se testira valjanost hipoteza kontinuirane numeričke vrijednosti te s obzirom na to da su grupe nezavisne i da je nezavisna varijabla kategorička, podatci su analizirani metodom analize varijance (ANOVA). Naravno, kako bi se ona mogla koristiti potrebno je zadovoljiti dodatne početne pretpostavke: da je distribucija podataka unutar svake ispitne grupe normalne distribucije te da u svakog grupi postoji homogenost varijanci. Također je poželjno imati balansiran dizajn istraživanja: da je broj ispitanika u svakoj ispitnog grupi jednak. Narušavanje svakog zahtjeva ili pretpostavke kod

nebalansiranog istraživanje može dovesti do ozbiljnog narušavanja vjerodostojnosti rezultata ove metode (Kent State University: One-Way ANOVA, 2016). U provedenom istraživanju kreirano je balansirano istraživanje u kojem su 3 grupe ispitanika po 30 sudionika.

U slučaju kada su zadovoljene tražene pretpostavke, tada se koristila standardna jednosmjerna analiza varijance. Za testiranje normalnosti distribucija koristio se Shapiro-Wilkov test (Shapiro & Wilk, 1965) te Kolmogorov-Smirnov test (Wilcox, 2005) a za testiranje homogenosti distribucija koristio se Leveneov test (Levene, 1960). U slučaju da je distribucija unutar grupa normalna no homogenost varijanci nije zadovoljena, koristio se Welchov test. Alternativno se može koristiti i Brown-Forsytheov test iako se pokazalo da je Welchov test u većini situacija prikladniji (Laerd statistics: One-way ANOVA, 2016). U slučajevima kada se analizom varijanci utvrdilo da postoji statistički značajna razlika u rezultatima između grupa, koristili su se odgovarajući post-hoc testovi. Fisherov LSD post-hoc test se koristio u slučaju kada je homogenost varijanci bila zadovoljena a kada to nije bio slučaj, koristio se Games-Howellov post-hoc test (Scheffe, 1999; Howell, 2012).

U slučaju kada normalnost distribucija nije bila zadovoljena, koristio se analogni neparametrijski Kruskal-Wallisov H test (Kruskal & Wallis, 1952). Kada se otkrila statistički značajna razlika prilikom korištenja Kruskal-Wallisovog testa, tada se taj test ponovio za svaki uređeni par grupa kako bi se precizno odredilo između kojih grupa postoji statistički značajna razlika. Sva ispitivanja su provedena na razini značajnosti od 0,05.



Slika 4.2. Odabir statističke metode za analizu rezultata

4.3. Rezultati analize motivacijskih upitnika

Hipoteza H1 ovog istraživanja ispituje se preko dva testa. Utvrđuje se razlika između grupa u:

- percepciji intrinzične motivacije korisnika, izmjereno standardiziranim upitnikom na temelju teorije samoodređenja (Self-determination theory, 2015), te
- percepciji korisnika o njihovom "stanju protoka", izmjereno standardiziranim upitnikom prema motivacijskoj teoriji Csikszentmihalyija o stanju protoka (Jackson & Marsh, 1996).

Prema teoriji samoodređenja, razvijeni su standardizirani upitnici za različite domene primjene: mjerenje percepcije korisnika o motivaciji prilikom izvršavanja nekog zadatka, izvršavanja neke aktivnost, čitanja teksta i sl. U ovom istraživanju se koristio upitnik za mjerenje percepcije o motivaciji prilikom izvršavanja aktivnosti koji se sastoji od 25 tvrdnji. Korisnik za svaku tvrdnju mora izraziti razinu slaganja na skali od 1 do 7 gdje 1 predstavlja potpuno neslaganje s izrečenom tvrdnjom dok 7 predstavlja potpuno slaganje s izrečenom tvrdnjom. Iako se upitnik sastoji od 25 tvrdnji, samo 8 tvrdnji se direktno odnosi na mjerenje intrinzične motivacije: tvrdnje 3, 5, 7, 11, 12(obrnuo), 15, 17 i 23. Ostale tvrdnje se odnose na druge koncepte koji predstavljaju pozitivne (odnosno negative) prediktore za percepciju o intrinzičnoj motivaciji. Tvrdnje iz upitnika se nalaze u prilogu.

Upitnik za mjerenje stanja protoka prema Csikszentmihalyjevoj teoriji se sastoji od 36 tvrdnji s kojima korisnik mora izraziti svoju razinu slaganja Likertovom skalom od 1 do 5 gdje 1 predstavlja potpuno neslaganje a 5 potpuno slaganje s navedenom tvrdnjom. Postoje dva osnovna modela prema kojima se može mjeriti stanje protoka: jednofaktorski model te devetfaktorski model. U ovom istraživanju se koristio jednofaktorski model jer je on prikladniji za dokazivanje hipoteze koja se razmatra. Kod devetfaktorskog modela stanje protoka se promatra kroz devet osnovnih faktora koji čine stanje protoka: balans težine i vještine, spajanje djelovanja i svijesti, jasnoća ciljeva, jasnoća povratne informacije, razina koncentracije, paradoks kontrole, gubitak samosvjesnosti, transformacija vremena i iskustvo samodostatnosti aktivnosti (autotelic activity). Analiza po faktorima nije potrebna za dokazivanje postavljene hipoteze. Tvrdnje iz upitnika se nalaze u prilogu.

4.3.1. Intrinzična motivacija


Nakon dobivenih rezultata, provedena je statistička deskriptivna analiza te su dobiveni rezultati prikazani u tablici 4.1.

Tablica 4.1. Deskriptivna statistika - intrinzična motivacija

Grupa	N	Srednja vrijednost	Standardna devijacija	Minimum	Maksimum
(1) ASPS-B	30	45,733	6,987	27	55
(2) HD-1 Drum Tutor	30	44,733	7,763	25	53
(3) Video poduke	30	41,433	6,862	29	53

Iz tablice se vidi da najveću srednju vrijednost ima eksperimentalna grupa no kod kontrolne grupa koja je učila svirati set bubnjeva uz pomoć alternativnog softvera ta vrijednost je neznatno manja. Drugo kontrolna grupa ima nešto manju prosječnu vrijednost u odnosu na preostale grupe. Standardna devijacija je podjednaka kod svih grupa, nešto malo veću vrijednost ima prva kontrolna grupa. Kod minimalnih i maksimalnih vrijednosti ne vidimo značajnu razliku među grupama.

Kako bi se provela jednofaktorska analiza varijanci, potrebno je ispitati potrebne pretpostavke a to je normalnost distribucije po grupama te homogenost varijanci. Slika 4.3. prikazuje histograme po grupama za mjerenje intrinzične motivacije.



Slika 4.3. Histogrami po grupama - intrinzična motivacija

Iz histograma je grafički često teško odrediti je li distribucija normalna ili ne. Kako bi se odredila normalnost distribucije, koristio se Shapiro-Wilk test i Kolmogorov-Smirnov test. Rezultati oba testa su prikazani u sljedećoj tablici.

Tablica 4.2. Testiranje normaliteta - intrinzična motivacija

Grupa	Kolmogorov-Smirnov			Shapiro-Wilk		
	Statistika	Stupanj slobode	Značajnost	Statistika	Stupanj slobode	Značajnost
(1) ASPS-B	0,149	30	0,090	0,924	30	0,033
(2) HD-1 Drum Tutor	0,196	30	0,005	0,878	30	0,003
(3) Video poduke	0,139	30	0,147	0,954	30	0,218

Ako se pogledaju rezultati Kolmogorov-Smirnov testa, vidljivo je da druga grupa ne zadovoljava normalnost distribucije dok kod Shapiro-Wilk test niti prva niti druga grupa ne zadovoljava normalnost distribucije. Jedino treća ispitna grupa zadovoljava normalnost distribucije kod oba testa što je otprilike vidljivo i kroz grafički prikaz histograma. S obzirom na ove rezultate, izvršen je neparametrijski Kruskal-Wallisov test kako bi se utvrdilo postoji li statistički značajna razlika u rezultatima između ispitnih grupa.

Tablica 4.3. Kruskal-Wallisov test - intrinzična motivacija

Grupa	N	Prosjeak rangova	Motivacija	
(1) ASPS-B	30	51,65	Hi-kvadrat	6,431
(2) HD-1 Drum Tutor	30	49,10	Stupanj slobode	2
(3) Video poduke	30	35,75	Značajnost	0,040

S obzirom na to da je vrijednost značajnosti manja od 0,05, utvrđeno je kako postoji statistički značajna razlika u prosječnoj vrijednosti motivacije između promatranih grupa. Kako bi se točno odredilo između kojih grupa, potrebno je provesti ponovno isti test za svaku kombinaciju grupa posebno. Prema prosjeku rangova vidljivo je kako zasigurno neće biti razlike između prve i druge ispitne grupe jer je njihov prosjek gotovo jednak. Razlika će sigurno postojati između prve i treće ispitne grupe jer je razlika između njihovih prosjeka rangova najveća.

Tablica 4.4. Kruskal-Wallisov test između prve i treće grupe - intrinzična motivacija

Grupa	N	Prosjeak rangova	Motivacija	
(1) ASPS-B	30	35,93	Hi-kvadrat	5,823
(3) Video poduke	30	25,07	Stupanj slobode	1
Ukupno	60		Značajnost	0,016

Prema rezultatima koji su vidljivi iz tablice, s obzirom na to da je razina značajnosti manja od 0,05, može se zaključiti kako postoji statistički značajna razlika u razini intrinzične motivacije između eksperimentalne grupe i kontrolne grupe koja je učila svirati set bubnjeva korištenjem video poduka, $X^2(1) = 5,823$, $p = 0,016$, s prosjekom rangova: 35,93 za eksperimentalnu

grupu i 25,07 za kontrolnu grupu. Na temelju hi-kvadrata, ako ga se podijeli s N-1, dobit će se postotak u kojoj mjeri se razlika može pripisati različitoj metodi učenja sviranja: taj postotak iznosi 9,87%.

Prema istom testu također je utvrđeno da ne postoji statistički značajna razlika u razini intrinzične motivacije između eksperimentalne grupe i kontrolne grupe koja je učila svirati set bubnjeva putem alternativnog računalnog softvera, $X^2(1) = 0,101$, $p = 0,750$, s prosjekom rangova: 31,22 za eksperimentalnu grupu i 29,78 za kontrolnu grupu. Što se tiče razlike između dvije kontrolne grupe, iako je vrijednost značajnosti blizu graničnoj vrijednosti, utvrđeno je da ne postoji statistički značajna razlika u razini intrinzične motivacije, $X^2(1) = 3,680$, $p = 0,055$, s prosjekom rangova: 34,82 za prvu kontrolnu grupu i 25,18 za drugu kontrolnu grupu. Iako je vidljivo da razlika u prosjeku rangova postoji, ona nije statistički značajna.

Iako je eksperimentalna grupa ostvarila statistički značajnu razliku u razini intrinzične motivacije u odnosu na jednu kontrolnu grupu, nije ostvarena statistički značajna razlika u odnosu na drugu kontrolnu grupu stoga se hipoteza H1A djelomično prihvaća.

4.3.2. Stanje protoka


Nakon prikupljanja podataka o stanju protoka polaznika istraživanja, provedena je statistička deskriptivna analiza te su dobiveni sljedeći rezultati.

Tablica 4.5. Deskriptivna statistika - stanje protoka

Grupa	N	Srednja vrijednost	Standardna devijacija	Minimum	Maksimum
(1) ASPS-B	30	145,133	21,684	101	179
(2) HD-1 Drum Tutor	30	143,500	23,922	97	176
(3) Video poduke	30	131,833	18,400	100	174

Rezultati ovog upitnika se poprilično podudaraju s rezultatima iz upitnika o intrinzičnoj motivaciji: eksperimentalna grupa ima najveću srednju vrijednost, prva kontrolna grupa ima neznatno manju srednju vrijednost dok se vidi određena razlika u odnosu na drugu kontrolnu grupu. Standardna devijacija je nešto malo manja kod druge kontrolne grupe. Kod minimalnih i maksimalnih vrijednosti vidljivo je kako ne postoji neka uočljiva razlika između sve tri ispitne grupe.

Kao i kod prethodne analize, potrebno je utvrditi postoji li normalnost distribucije i homogenost varijanci kako bi se provela jednofaktorska analiza kako bi se utvrdilo postoji li statistički značajna razlika u srednjoj vrijednosti između promatranih grupa.



Slika 4.4. Histogrami po grupama - stanje protoka

Iz histograma je vidljivo kako sve tri grupe imaju približno sličan oblik distribucije podataka. Kako bi se odredila numerički normalnost distribucije, provedena su dva testa: Shapiro-Wilk test i Kolmogorov-Smirnov test. Rezultati su prikazani u sljedećoj tablici.

Tablica 4.6. Testiranje normaliteta - stanje protoka

Grupa	Kolmogorov-Smirnov			Shapiro-Wilk		
	Statistika	Stupanj slobode	Značajnost	Statistika	Stupanj slobode	Značajnost
(1) ASPS-B	0,142	30	0,125	0,947	30	0,138
(2) HD-1 Drum Tutor	0,125	30	0,200	0,936	30	0,070
(3) Video poduke	0,062	30	0,200	0,985	30	0,940

Prema dobivenim podacima, može se zaključiti kako su sve tri ispitne grupe zadovoljile normalnost distribucije, što nije bio slučaj kod ispitivanja intrinzične motivacije. To se moglo i pretpostaviti jer se ispitivanje intrinzične motivacije vršilo na svega osam tvrdnji koje su bodovane na skali od 1 do 7 dok kod mjerenja stanja protoka u upitniku se nalazi 36 tvrdnji koje su se bodovale standardnom Likertovom skalom od 1 do 5. S obzirom na to da je normalnost distribucije zadovoljena, potrebno je još provjeriti je li zadovoljena pretpostavka o homogenosti varijanci. Sljedeća tablica prikazuje rezultate Leveneovog testa.

Tablica 4.7. Leveneov test - stanje protoka

Leveneova statistika	Stupanj slobode 1	Stupanj slobode 2	Značajnost
1,398	2	87	0,253

Prema Leveleovom testu može se vidjeti kako je homogenost varijanci zadovoljena što se moglo i pretpostaviti jer se kroz deskriptivnu statistiku vidjela mala razlika u razlici standardne devijacije između grupa. S obzirom na to da su zadovoljene pretpostavke za provedbu jednofaktorske analize varijanci, u sljedećoj tablici su prikazani rezultati tog testa.

Tablica 4.8. Jednofaktorska analiza varijanci - stanje protoka

	Suma kvadrata	Stupanj slobode	Kvadrat prosjeka	F	Značajnost
Između grupa	3156,689	2	1578,344	3,429	0,037
Unutar grupa	40049,133	87	460,335		
Ukupno	43205,822	89			

S obzirom da je značajnost manja od 0,05, može se zaključiti kako postoji statistički značajna razlika u razini stanja protoka između promatranih ispitnih grupa kroz prikazane rezultate ANOVA metode, $F(2,87) = 3,429$, $p = 0,037$. Kako bi se utvrdilo točno između kojih grupa postoji statistički značajna razlika, potrebno je provesti post-hoc test. S obzirom da je homogenost varijanci zadovoljena, proveden je Fisherov LSD test te su rezultati tog testa prikazani u sljedećoj tablici.

Tablica 4.9. Fisherov LSD test - stanje protoka

		(I) Grupa	(J) Grupa	Razlika u prosjeku (I-J)	Standardna greška	Značajnost	95% interval povjerenja	
							Donja granica	Gornja granica
Fisherov LSD test	ASPS-B	HD-1		1,633	5,540	0,769	-9,38	12,64
		Video		13,300	5,540	0,018	2,29	24,31
	HD-1	ASPS-B		-1,633	5,540	0,769	-12,64	9,38
		Video		11,667	5,540	0,038	0,66	22,68
	Video	ASPS-B		-13,300	5,540	0,018	-24,31	-2,29
		HD-1		-11,667	5,540	0,038	-22,68	-0,66

Na temelju dobivenih podataka može se vidjeti kako postoji statistički značajna razlika u razini stanja protoka između eksperimentalne grupe u odnosu na kontrolnu grupu koja je učila svirati set bubnjeva putem video poduka, s obzirom da je vrijednost značajnosti manja od 0,05. Razlika u odnosu na kontrolnu grupu koja je učila svirati putem korištenja alternativnog računalnog softvera ne postoji, $p = 0,769$.

Zanimljivo je primijetiti kako u ovom slučaju postoji i statistički značajna razlika između dvije kontrolne grupe, $p = 0,038$. Ovaj rezultat ukazuje da je korištenje interaktivnog računalnog softvera više motivirajuće za korisnike u odnosu na učenje uz obične video materijale koji nisu u stanju dati adekvatnu povratnu informaciju prilikom učenja sviranja seta bubnjeva.

Na temelju ovih rezultata, s obzirom na to da je ostvarena statistički značajna razlika u razini stanja protoka eksperimentalne grupe u odnosu na drugu kontrolnu grupu, hipoteza H1B se ne može u cijelosti prihvatiti stoga se ona prihvaća djelomično.

4.3.3. Prihvaćanje ili odbacivanje hipoteze H1

S obzirom da su hipoteze H1A i H1B djelomično prihvaćene, time se djelomično prihvaća i hipoteza H1. Utvrđena je statistički značajna razlika u percepciji razine intrinzične motivacije i percepciji razine stanja protoka eksperimentalne grupe u odnosu na kontrolnu grupu koja je koristila video poduke u procesu učenja sviranja seta bubnjeva. Eksperimentalna grupa nije ostvarila veću razinu motivacije i razinu stanja protoka u odnosu na prvu kontrolnu grupu koja je koristila alternativni računalni softver za učenje sviranja seta bubnjeva. Također je utvrđeno kako je prva kontrolna grupa ostvarila statistički značajnu razliku u percepciji razine stanja protoka u odnosu na drugu kontrolnu grupu.

4.4. Rezultati analize testiranja vještine sviranja

Hipoteza H2 se ispitivala preko tri testa. Utvrđena je razlika između grupa u:

- preciznosti sviranja korisnika kroz mjerenje koliko je ukupno točnih nota odsvirano u završnoj vježbi,
- količini naučenih uzoraka kroz zbroj koliko je uzoraka odsvirano bez greške u završnoj vježbi, te
- ocjeni nezavisnog eksperta audio zapisa završne vježbe.

Mjerenjem preciznosti sviranja, tj. praćenjem koliko nota od ukupnog broja nota u završnoj vježbi je točno odsvirano, utvrdilo se u kojoj je mjeri korisnik uspio savladati vještinu sviranja seta bubnjeva. Očito je da je onaj korisnik koji je odsvirao više točnih nota u tome bio uspješniji. Također, mjerenjem koliko je uzoraka korisnik u završnoj vježbi uspio odsvirati bez greške ustanovilo se tko je naučio više uzoraka i time naučio više od ostalih. Na kraju, nezavisni ekspert je poslušao audio zapise završnih vježbi te svakog korisnika ocijenio s ocjenom od 1 do 5. Radi bolje gradacije, ekspert je odredio ocjenu s preciznošću od jedne decimale. Na temelju ovih podataka se može potvrditi ili odbaciti hipoteza H2 koja

pretpostavlja da će korisnici koji su učili svirati set bubnjeva preko kreiranog prototipa koji se temelji na kreiranom konceptualnom modelu naučiti bolje svirati od korisnika iz kontrolnih grupa.

4.4.1. Preciznost sviranja


Kako bi izmjerili preciznost sviranja korisnika, mjerila se količina točno odsviranih nota u završnoj vježbi. Završna vježba se sastoji od 628 nota koje je korisnik trebao odsvirati unutar 64 ritmička uzorka. Na temelju prikupljenih podataka, provedena je statistička deskriptivna analiza te su dobiveni podatci prikazani u tablici 4.10.

Tablica 4.10. Deskriptivna statistika - točno odsvirane note

Grupa	N	Srednja vrijednost	Standardna devijacija	Minimum	Maksimum
(1) ASPS-B	30	557,733	49,134	455	626
(2) HD-1 Drum Tutor	30	491,733	76,530	362	608
(3) Video poduke	30	444,267	58,949	368	578

Iz tablice se može vidjeti da je srednja vrijednost najviša u eksperimentalnoj grupi dok je kontrolna grupa koja je koristila alternativni računalni softver uspješnija od kontrolne grupe koja je koristila samo video poduke. Standardna devijacija je najmanja u eksperimentalnoj grupi što sugerira da ima najkonzistentnije rezultate. Najveća disperzija je u drugoj grupi i dosta je veća od preostale dvije grupe. Iz toga se može zaključiti da je konzistentnost u učenju ovom metodom nešto slabija. Ono što je zanimljivo primijetiti je minimalna vrijednost koja je dosta veća u eksperimentalnog grupi u odnosu na obje kontrolne grupe. To sugerira da su koristi od učenja novom metodom imali oni koji bi ostvarili ispodprosječne rezultate. Razlika se može vidjeti i u maksimalnom broju točno odsviranih nota no ta razlika više nije tako izražena, no ipak postoji. Podatci o minimumu i maksimumu sugeriraju da su svi korisnici nove metode učenja imali koristi od načina učenja kojim su učili. Sljedeća analiza će pokazati da li je ta korist i statistički značajna.

Kako bi se provela jednofaktorska analiza varijance, potrebno je ispitati zadovoljavaju li podatci početne pretpostavke a to je normalnost distribucije po grupama kao i homogenost varijanci između grupa. Slika 4.5. prikazuje dobivene histograme za svaku ispitnu grupu za analizu točno odsviranih nota u završnoj vježbi.



Slika 4.5. Histogrami po grupama - točno odsvirane note

Kako bi se odredilo zadovoljavaju li prikazani histogrami normalitet, provedeni su Shapiro-Wilk test i Kolmogorov-Smirnov test a rezultati testova su prikazani u sljedećoj tablici.

Tablica 4.11. Testiranje normaliteta - točno odsvirane note

Grupa	Kolmogorov-Smirnov			Shapiro-Wilk		
	Statistika	Stupanj slobode	Značajnost	Statistika	Stupanj slobode	Značajnost
(1) ASPS-B	0,138	30	0,152	0,934	30	0,063
(2) HD-1 Drum Tutor	0,112	30	0,200	0,942	30	0,101
(3) Video poduke	0,119	30	0,200	0,939	30	0,085

Iz tablice se može vidjeti da je značajnost kod oba testa za sve grupe veća od 0,05 te se na temelju toga može zaključiti da sve tri grupe imaju približno normalnu distribuciju. Iako eksperimentalna grupa prema Shapiro-Wilk testu nije daleko od same granice, još uvijek se može reći da je distribucija podataka normalna. Ono što preostaje ispitati jesu li varijance ispitnih grupa homogene. Prema Leveneovom testu dobivaju se sljedeći rezultati.

Tablica 4.12. Leveneov test - točno odsvirane note

Leveneova statistika	Stupanj slobode 1	Stupanj slobode 2	Značajnost
3,915	2	87	0,024

S obzirom da je značajnost Levenovog testa manja od 0,05 može se zaključiti da grupe ne zadovoljavaju pretpostavku homogenosti. U tom slučaju koristio se Welchov test kako bi se utvrdilo postoji li statistički značajna razlika u rezultatu.

Tablica 4.13. Welchov test - točno odsvirane note

	Statistika	Stupanj slobode 1	Stupanj slobode 2	Značajnost
Welch	33,182	2	56,354	0,000

Na temelju dobivenih rezultata može se zaključiti kako postoji statistički značajna razlika u rezultatu između grupa jer je značajnost manja od 0,05. Kako bi se utvrdilo između kojih grupa postoji razlika, napravljen je post-hoc Games-Howellov test koji se koristi u slučaju nehomogenosti varijance.

Tablica 4.14. Games-Howellov test - točno odsvirane note

	(I) Grupa	(J) Grupa	Razlika u prosjeku (I-J)	Standardna greška	Značajnost	95% interval povjerenja	
						Donja granica	Gornja granica
Games-Howell	ASPS-B	HD-1	66,000	16,604	0,001	25,88	106,12
		Video	113,467	14,011	0,000	79,74	147,20
	HD-1	ASPS-B	-66,000	16,604	0,001	-106,12	-25,88
		Video	47,467	17,637	0,025	4,97	89,96
	Video	ASPS-B	-113,467	14,011	0,000	-147,20	-79,74
		HD-1	-47,467	17,637	0,025	-89,96	-4,97

Iz tablice se može vidjeti usporedba između svake grupe sa svakom preostalom grupom. Najznačajniji dio tablice je usporedba eksperimentalne grupe s kontrolnim grupama i ta usporedba se može vidjeti u prva dva retka tablice. S obzirom na dobivenu značajnost koja je u oba slučaja daleko ispod 0,05 može se zaključiti kako postoji statistički značajna razlika između količine točno odsviranih nota na završnoj vježbi s obzirom na metodu učenja sviranja seta bubnjeva. Eksperimentalna grupa je ostvarila statistički značajnu razliku u odnosu na obje kontrolne grupe. Rezultati također pokazuju da postoji statistički značajna razlika između dvije kontrolne grupe u korist učenja putem alternativnog računalnog softvera. Prema tome se može također zaključiti kako je učenje sviranja seta bubnjeva putem interaktivnih računalnih softvera prikladnije od učenja putem korištenja običnih multimedijских materijala.

Korisnici koji su učili svirati set bubnjeva putem ASPS-B-a su ostvarili bolji prosječni rezultat u preciznosti sviranja od korisnika alternativnih pristupa samostalnog učenja stoga je hipoteza H2A prihvaćena.

4.4.2. Naučeni uzorci

Kako bi se izmjerilo koliko je svaki korisnik naučio ritmičkih uzoraka, u završnoj vježbi mjerilo se koliko je ritmičkih uzoraka korisnik odsvirao bez greške. Završna vježba se sastojala od odabranih 64 ritmičkih uzoraka iz cjelokupnog skupa ritmičkih uzoraka. Sve grupe ritmičkih uzoraka koje su se učile tijekom procesa učenja sviranja su ravnomjerno

zastupljene u završnoj vježbi. Nakon prikupljanja podataka, provedena je deskriptivna statistička analiza te su dobiveni sljedeći rezultati.


Tablica 4.15. Deskriptivna statistika - naučeni uzorci

Grupa	N	Srednja vrijednost	Standardna devijacija	Minimum	Maksimum
(1) ASPS-B	30	38,733	13,323	13	61
(2) HD-1 Drum Tutor	30	30,233	12,993	10	52
(3) Video poduke	30	23,000	9,476	10	42

Iz tablice se opet može vidjeti sličnost rezultata s rezultatima kod mjerenja količine točno odsviranih nota: najveću prosječnu vrijednost ima eksperimentalna grupa dok je kontrolna grupa koja je učila svirati uz pomoć računalnog softvera bolja u odnosu na grupu koja je učila uz neinteraktivne multimedijske video poduke. Što se tiče standardne devijacije, rezultati su nešto drugačiji nego kod ispitivanja točno odsviranih nota. U ovom slučaju najmanju standardnu devijaciju ima treća grupa ispitanika dok su standardne devijacije prve i druge grupe ispitanika podjednake. Tu se može zaključiti da je konzistentnost dobivenih rezultata najveća u trećoj grupi ispitanika iako je razlika manja nego kod mjerenja točno odsviranih nota.

Što se tiče dobivenih minimalnih vrijednosti, može se vidjeti da su one podjednake. Vrlo mala razlika ide u korist eksperimentalne grupe. Što se tiče vršnih vrijednosti, tu već postoji veća razlika: eksperimentalna grupa je u vidljivoj prednosti u odnosu na kontrolne grupe kao i što je kontrolna grupa koja je učila svirati korištenjem računalnog softvera u vidljivoj prednosti u odnosu na zadnju grupu. Eksperimentalna grupa se približila maksimalnom broju točno odsviranih uzoraka, jednako kao i kod mjerenja točno odsviranih nota. Prema ovom mjerenju ispada da su oni uspješniji imali veću korist od učenja novim načinom učenja sviranja seta bubnjeva. U kombinaciji s dobivenim rezultatima kod mjerenja količine točno odsviranih nota, vidljiva je korist eksperimentalne grupe u odnosu na kontrolne grupe.

U nastavku se mogu vidjeti histogrami za svaku pojedinu grupu za točno odsvirane uzorke na završnoj vježbi.



Slika 4.6. Histogrami po grupama - naučeni uzorci

Kako bi se odredila normalnost distribucije unutar svake grupe, proveden je Shapiro-Wilk test i Kolmogorov-Smirnov test te su rezultati prikazani u sljedećoj tablici.

Tablica 4.16. Testiranje normaliteta - naučeni uzorci

Grupa	Kolmogorov-Smirnov			Shapiro-Wilk		
	Statistika	Stupanj slobode	Značajnost	Statistika	Stupanj slobode	Značajnost
(1) ASPS-B	0,141	30	0,134	0,950	30	0,163
(2) HD-1 Drum Tutor	0,106	30	0,200	0,945	30	0,128
(3) Video poduke	0,137	30	0,160	0,945	30	0,122

Prema dobivenim rezultatima, vidi se da je značajnost kod svih grupa u oba testa veća od 0,05 te se na temelju toga može zaključiti kako je zadovoljena pretpostavka normalnosti distribucije za sve grupe ovog mjerenja. Što se tiče homogenosti varijanci, dobiveni su sljedeći rezultati.

Tablica 4.17. Leveneov test - naučeni uzorci

Leveneova statistika	Stupanj slobode 1	Stupanj slobode 2	Značajnost
3,039	2	87	0,053

Kao što je vidljivo iz tablice, Levenov test ukazuje da su varijance homogene no na graničnoj vrijednosti. S obzirom na to da su obje početne pretpostavke zadovoljene, provedena je jednofaktorska analiza nad ovim podacima te su dobiveni sljedeći rezultati.

Tablica 4.18. Jednofaktorska analiza varijanci - naučeni uzorci

	Suma kvadrata	Stupanj slobode	Kvadrat prosjeka	F	Značajnost
Između grupa	3721,089	2	1860,544	12,799	0,000
Unutar grupa	12647,233	87	145,370		
Ukupno	16368,322	89			

Na temelju dobivenih rezultata može se zaključiti kako postoji statistički značajna razlika između grupa jer je razina značajnosti ispod 0,05. S obzirom na to da je homogenost varijanci na graničnoj vrijednosti, proveden je i Welchov test te je dobivena ista razina značajnosti ako se rezultat gleda s preciznosti na tri decimale. Kako bi se utvrdilo između kojih grupa točno postoji razlika, proveden je Fisherov LSD test. Također je proveden i Games-Howellov test s obzirom na graničnu vrijednost homogenosti varijanci. Dobiveni rezultati su prikazani u tablici 4.19.

Tablica 4.19. Fisherov LSD test i Games-Howellov test - naučeni uzorci

	(I) Grupa	(J) Grupa	Razlika u prosjeku (I-J)	Standardna greška	Značajnost	95% interval povjerenja	
						Donja granica	Gornja granica
Fisher LSD	ASPS-B	HD-1	8,500	3,113	0,008	2,31	14,69
		Video	15,733	3,113	0,000	9,55	21,92
	HD-1	ASPS-B	-8,500	3,113	0,008	-14,69	-2,31
		Video	7,233	3,113	0,022	1,05	13,42
	Video	ASPS-B	-15,733	3,113	0,000	-21,92	-9,55
		HD-1	-7,233	3,113	0,022	-13,42	-1,05
Games-Howell	ASPS-B	HD-1	8,500	3,398	0,040	0,33	16,67
		Video	15,733	2,985	0,000	8,53	22,93
	HD-1	ASPS-B	-8,500	3,398	0,040	-16,67	-0,33
		Video	7,233	2,936	0,044	0,15	14,31
	Video	ASPS-B	-15,733	2,985	0,000	-22,93	-8,53
		HD-1	-7,233	2,936	0,044	-14,31	-0,15

Iz tablice se može vidjeti da su razine značajnosti kod svih usporedbi grupa ispod razine od 0,05 stoga se može zaključiti kako postoji statistički značajna razlika između svih testiranih grupa. Iz tablice je vidljivo da su vrijednosti prema Games-Howellovom testu bliže samoj granici značajnosti no još su uvijek te vrijednosti manje od 0,05 stoga su ovi rezultati konzistentni s Fisherovim LSD testom. Na temelju ovoga može se zaključiti da postoji statistički značajna razlika između količine naučenih ritmičkih uzoraka u odnosu na metodu učenja sviranja seta bubnjeva u korist eksperimentalne grupe. Također je vidljivo, kao i kod mjerenja točno odsviranih nota, da postoji statistički značajna razlika između kontrolnih grupa u korist prve grupe.

Na temelju ovih podataka zaključujemo kako je uspješno ubrzan proces učenja te da su ispitanici eksperimentalne grupe u istom vremenskom periodu naučili više ritmičkih uzoraka u odnosu na kontrolne grupe i samim time je hipoteza H2B prihvaćena.

4.4.3. Ocjena eksperta


U prijašnjim analizama broj točno odsviranih uzoraka i broj točno odsviranih nota mjerilo je računalo. Ono što se ovom analizom pokušava ustanoviti je da li će i nezavisni ekspert moći uočiti razliku u kvaliteti sviranja pojedinih sudionika istraživanja. Kako bi se to odredilo, sve završne vježbe su snimane u audio zapisu te su pod kodiranim imenima predane nezavisnom ekspertu na ocjenjivanje. Ekspert nije znao kojoj ispitnoj grupi pripada pojedini audio zapis. Ekspert je trebao poslušati svaki dobiveni audio zapis te dati svoju procjenu kvalitete sviranja kroz dodjeljivanje ocjene u rasponu od 1 do 5. Radi bolje gradacije, mogao je odrediti i prvu decimalu kod dodjele ocjene. Ekspert je dobio note završne vježbe kako bi mogao znati što su ispitanici trebali svirati. Nakon što je ekspert sve ispitanike ocijenio, provedena je statistička deskriptivna analiza te su dobiveni sljedeći rezultati.

Tablica 4.20. Deskriptivna statistika - ocjena eksperta

Grupa	N	Srednja vrijednost	Standardna devijacija	Minimum	Maksimum
(1) ASPS-B	30	4,113	0,588	3,0	5,0
(2) HD-1 Drum Tutor	30	3,703	0,843	2,0	4,8
(3) Video poduke	30	3,623	0,787	2,4	4,9

Dobiveni rezultati su konzistentni s dosadašnjim rezultatima no ovaj put je razlika dosta manja nego kod prijašnjih analiza. Eksperimentalna grupa ima najveću prosječnu vrijednost no je li ona značajna, to će pokazati naredno testiranje. Standardna devijacija je nešto manja u eksperimentalnoj grupi u odnosu na kontrolne grupe. Što se tiče minimalne vrijednosti, vidi se da eksperimentalna grupa ima nešto veću vrijednost nego ostale grupe. Ono što pomalo iznenađuje, s obzirom na dosadašnje rezultate, je to da je minimalna vrijednost druge grupe manja u odnosu na treću grupu. Što se tiče maksimalnih vrijednosti, tu se ne vidi značajna razlika.

Kao i kod dosadašnjih analiza, slijedi slika histograma po grupama kako bi se grafički mogla vidjeti distribucija dobivenih rezultata.



Slika 4.7. Histogrami po grupama - ocjena eksperta

Kako bi se odredila normalnost distribucije unutar svake grupe, opet su provedeni Shapiro-Wilk test i Kolmogorov-Smirnov test. Rezultati su prikazani u sljedećoj tablici.

Tablica 4.21. Testiranje normaliteta - ocjena eksperta

Grupa	Kolmogorov-Smirnov			Shapiro-Wilk		
	Statistika	Stupanj slobode	Značajnost	Statistika	Stupanj slobode	Značajnost
(1) ASPS-B	0,145	30	0,111	0,941	30	0,095
(2) HD-1 Drum Tutor	0,122	30	0,200	0,926	30	0,038
(3) Video poduke	0,117	30	0,200	0,939	30	0,084

Prema dobivenim rezultatima može se vidjeti jedna nekonzistentnost između Kolmogorov-Smirnov testa i Shapiro-Wilk testa: prema Shapiro-Wilk testu druga ispitna grupa ne zadovoljava normalnost distribucije jer je značajnost manja od 0,05. Za preostale grupe vidi se da je pretpostavka o normalnosti distribucije zadovoljena. Određeni izvori sugeriraju da je analiza varijance dovoljno robusna za situacije kada normalnost distribucije nije u potpunosti zadovoljena, dovoljno je da distribucija bude barem približno normalna, i to u slučajevima kada se radi balansirano istraživanje te je broj ispitanika dovoljno velik (Kent State University: One-Way ANOVA, 2016). S obzirom da je prema Kolmogorov-Smirnov testu normalnost zadovoljena a prema Shapiro-Wilk testu grupa koja nije zadovoljila normalitet relativno blizu potrebne granice, odlučeno je kako će se provesti jednofaktorska analiza varijanci.

U sljedećoj tablici nalaze se rezultati ispitivanja homogenosti varijanci.

Tablica 4.22. Leveneov test - ocjena eksperta

Leveneova statistika	Stupanj slobode 1	Stupanj slobode 2	Značajnost
2,128	2	87	0,125

Iz tablice se može zaključiti kako je homogenost varijanci u ovom slučaju zadovoljena te da se može provesti standardna jednofaktorska analiza varijanci.

Tablica 4.23. Jednofaktorska analiza varijanci - ocjena eksperta

	Suma kvadrata	Stupanj slobode	Kvadrat prosjeka	F	Značajnost
Između grupa	4,146	2	2,073	3,713	0,028
Unutar grupa	48,578	87	0,558		
Ukupno	52,724	89			

S obzirom na značajnost koja je manja od 0,05 se izvodi zaključak kako postoji statistički značajna razlika između ispitnih grupa u dobivenim rezultatima. S obzirom da je homogenost varijanci zadovoljena, proveden je Fisherov LSD test kako bi se utvrdila međusobna razlika između pojedinih grupa.

Tablica 4.24. Fisherov LSD test - ocjena eksperta

			Razlika u prosjeku (I-J)	Standardna greška	Značajnost	95% interval povjerenja	
		Donja granica				Gornja granica	
Fisher LSD	(I) Grupa	(J) Grupa					
	ASPS-B	HD-1	0,410	0,193	0,036	0,027	0,793
		Video	0,490	0,193	0,013	0,107	0,873
	HD-1	ASPS-B	-0,410	0,193	0,036	-0,793	-0,027
		Video	0,080	0,193	0,679	-0,303	0,463
	Video	ASPS-B	-0,490	0,193	0,013	-0,873	-0,107
HD-1		-0,080	0,193	0,679	-0,463	0,303	

Prema Fisherovom LSD testu, utvrđena je statistička značajna razlika između eksperimentalne grupe u odnosu na obje kontrolne grupe. Što se tiče razlike između kontrolnih grupa, rezultati pokazuju da ne postoji statistički značajna razlika u rezultatu.

Na temelju dobivenih podataka može se zaključiti kako je eksperimentalna grupa ocjenjena u prosjeku sa statistički značajno većom ocjenom u odnosu na obje kontrolne grupe te se time hipoteza H2C prihvata.

4.4.4. Prihvatanje ili odbacivanje hipoteze H2

Eksperimentalna grupa je ostvarila statistički značajnu razliku u prosjeku ukupnog broja točno odsviranih nota završne vježbe, prosjeku količine naučenih ritmičkih uzoraka i prosječnoj ocjeni eksperta u odnosu na obje kontrolne grupe. Na temelju dobivenih rezultata može se sa sigurnošću reći da je hipoteza H2 potvrđena.

4.5. Ograničenja istraživanja i moguća daljnja istraživanja

Neizbježna ograničenja ovog istraživanja, između ostalog, uzrokuju i određene nedostatke kreiranog prototipa obzirom da se sustav isključivo bavi točnošću izvedbe zadanih primjera. Iako je vrlo važan dio usavršavanja izvođačke tehnike, točnost izvedbe sama po sebi nije jedini - čak niti glavni - element za završnu prosudbu o kvaliteti nečijeg sviranja.

Muzikalnost, maštovitost, originalnost, poznavanje stila i slično samo su neki od brojnih elemenata koji odlikuju umjetnički uspješnu glazbenu izvedbu a nisu mogli biti uključeni u okvire ovog istraživanja obzirom na njegova projektna, financijska i vremenska ograničenja.

Novokreirani sustav nije u tom smislu napravio iskorak prema naprijed u odnosu na postojeća rješenja obzirom da su sve ispitne grupe na isti način učile tehniku sviranja: kroz demonstraciju eksperta putem video materijala. Trenutno ne postoji bolji način samostalnog učenja tehnike sviranja osim ako se ne kreira neki hibridni način učenja gdje bi osim učenja uz pomoć računalnog softvera sudjelovao i instruktor, što je ujedno i jedan od smjerova u kojem bi se ovo istraživanje moglo nastaviti.

Također bi se moglo putem korištenja senzora i algoritama prepoznavanja pokreta putem video kamere detektirati pogreške ali ostale brojne tehničke elemente sviranja te njihove delikatne aspekte računala danas još ne mogu adekvatno evaluirati.

Istraživanje provedeno na početnicima koji nemaju prijašnjeg iskustva u sviranju glazbenih instrumenata pokazalo je da će oni kao samouci uz korištenje novog sustava naučiti točnije svirati zadane primjere od onih ispitanika koji će koristiti alternativne metode. Ovu prednost sustava treba pripisati njegovoj interaktivnosti te kvaliteti povratnih informacija koje dolaze u stvarnom vremenu. Ti čimbenici su posebno značajni kod početnika koji još nemaju iskustva u samoprocjeni svoje točnosti te općenito vještine sviranja. Primjerice, opaženo je da su korisnici video poduke mislili da su naučili određene uzorke a onda na završnoj vježbi, kada je sustav mjerio vremensko odstupanje od trenutka kada notu treba zaista odsvirati, pokazalo se da je njihova predodžba preciznosti bila kriva. Korisnici koji su koristili interaktivni sustav, koji je odmah pri vježbanju pokazao je li zadana nota točno odsvirana, su u procesu vježbanja radili samokorekciju vremenskog odstupanja i time odmah ispravljali učinjene pogreške. Ipak,

upitno je bi li razlika u rezultatu bila toliko velika kod korisnika koji već imaju razvijen osjećaj za ritam, koji nisu početnici i već imaju osnovno znanje i iskustvo. To je također jedan od mogućih smjerova daljnjeg istraživanja pri kojem bi značajnu ulogu trebalo odigrati fino podešavanje kriterija tolerancije pogrešaka ugrađenih u sustav a koji bi se prilagođavali zadanim tempima ili stilu te sadržaju primjera.

Da bi se mogle potvrditi ili opovrgnuti postavljene hipoteze, provedeno je ispitivanje motivacije na način da su formirane tri različite grupe nezavisnih korisnika koji su učili samo jednom od tri metode. Međutim, kada bi se provelo istraživanje pri kojem bi svi korisnici učili na tri različita načina i onda trebali odrediti koji način im je najviše odgovarao i bio najzanimljiviji, možda bi se dobili i drugačiji rezultati. To je također još jedna ideja za daljnje istraživanje.

Pri istraživanju su svi korisnici koristili isti nastavni sadržaj kako bi se izbjegla "vrebajuća varijabla" koja bi mogla uzrokovati različitosti rezultata te otežati evaluaciju. Sadržaj baze znanja, redoslijed primjera te posebice njihov glazbeni sadržaj kao i logika njihovog povezivanja u glazbeno suvislu te privlačnu cjelinu jest također dio sustava u kojem postoji jako mnogo prostora za usavršavanje u budućim inačicama.

Realna situacija je da svaka vrsta video poduke dostupna na tržištu koristi svoju metodu učenja, svoje primjere i uzorke dok HD-1 Drum Tutor ima svoju bazu znanja, koja je relativno skromna, čak i u odnosu na kreirani prototip. Da bi se sa sigurnošću evaluiralo koji je danas najbolji način za samostalno učenje sviranja seta bubnjeva, trebalo bi provesti drugačije istraživanje koje bi gledalo realno stanje svakog načina učenja usporedivo s kreiranim prototipom te kreiranom bazom znanja koja bi tada bila specifična za svaku metodu učenja. Pri tom bi trebalo uzeti u obzir individualnosti korisnika u što većoj mjeri.

Postoji mnogo smjerova u kojima se može nastaviti istraživati na ovim osnovama.

Jedna od ideja, koju su već neki projekti pokušali realizirati, je kreiranje glazbene škole na daljinu. U sustav bi tada trebalo integrirati audio i video komunikaciju putem interneta putem koje bi učenik mogao komunicirati s instruktorom.

Također, trebalo bi se detaljno pratiti aktivnosti učenika to jest nastavnik bi trebao imati načina da provjeri koliko je vremena korisnik kod kuće vježbao, što je vježbao i kakav mu je bio napredak, gdje je griješio i sl. Sustav bi se mogao prilagoditi tako da bude korišten u tom kontekstu te da prati vrijeme sviranja, da snima sve što učenik vježba te bi tada nastavnik pregledom tih podataka mogao imati uvid u vrijeme vježbanja, kada je učenik vježbao i koliko dugo, što je vježbao, gdje je učestalo griješio te bi na temelju tih informacija učeniku mogao dati adekvatniju povratnu informaciju odnosno upute za nastavak rada.

Na temelju ovog sustava mogao bi se kreirati proizvod koji bi ili bio komercijalan ili dostupan svima za korištenje. Dostupnost ovakvog proizvoda bi možda potaknula današnju generaciju koja odrasta uz digitalne tehnologije, računala, pametne telefone i društvene mreže da počne učiti svirati set bubnjeva na način koji bi njima bio pristupačniji. Također se u ovoj mogućnosti vidi i društveni doprinos: mnoge sredine nemaju glazbene škole ili udruge koje se bave podučavanjem sviranja seta bubnjeva. Ovakav proizvod bi omogućio da netko tko prije nije imao mogućnost učiti svirati set bubnjeva ili mu ona nije dostupna sad ima tu mogućnost.

U svakom slučaju, ovo područje je sigurno plodno za daljnja istraživanja obzirom zasigurno postoje mogućnosti za unaprjeđenje i daljnji razvoj, kako modela tako i sustava, kako u izravnoj domeni u kojoj se ovaj prototip kreirao, tako i šire, u domeni primjene računalne tehnologije u području učenja sviranja glazbenih instrumenata.

5. ZAKLJUČAK

Sagledavajući rezultate višegodišnjeg rada na ovom istraživanju može se zaključiti da su ostvarena početna očekivanja unatoč financijskim i vremenskim ograničenjima koja redovito prate realizaciju ovakvih projekata posebice u fazi evaluacije radi sudjelovanja velikog broja ispitanika.

U prvom dijelu ovog istraživanja predstavljen je pregled znanstvene literature o utjecaju slušanja i sviranja glazbe na čovjeka. Potom je prikazan pregled znanstvene literature o primjeni računalne tehnologije pri učenju osnovnih glazbenih znanja i vještina s posebnim naglaskom na primjenu računalne tehnologije kod samostalnog učenja sviranja glazbenih instrumenata. Identificirani su postojeći koncepti, njihove pozitivne karakteristike, posebnosti i specifičnosti te je kreiran njihov pregled.

Na temelju navedene teoretske podloge, kreiran je konceptualni model koji unaprjeđuje postojeće koncepte koji su se koristili u domeni učenja sviranja glazbenih instrumenata te je na tim osnovama kreiran prototip, računalni sustav, za samostalno učenje sviranja seta bubnjeva. Sustav koristi određene koncepte umjetne inteligencije te prati sviranje korisnika dajući prikladne povratne informacije kako bi optimizirao njegov proces učenja: učinio ga bržim i efikasnijim.

Kroz praktično istraživanje na stvarnim korisnicima, utvrđen je utjecaj korištenja osmišljenog modela i kreiranog sustava na motivaciju za rad kao i utjecaj na same ishode učenja. Utvrđeno je da postoji statistički značajna razlika u motivaciji korisnika koji su koristili kreirani sustav u odnosu na kontrolnu grupu koja je koristila klasične video poduke u procesu učenja sviranja no ne i na kontrolnu grupu koja je koristila alternativni računalni softver. Što se tiče ishoda učenja, ostvarena je statistički značajna razlika u odnosu na obje kontrolne grupe. Hipoteza H1 je djelomično potvrđena dok je hipoteza H2 u potpunosti potvrđena.

Kroz ovo istraživanje ostvareni su željeni ciljevi, potvrđena je jedna od hipoteza i samim time je ostvaren željeni znanstveni doprinos. Iako ovo istraživanje ima svoja ograničenja, njegovi pozitivni rezultati otvaraju mogućnosti za nove smjerove te daljnji razvoj i napredak u domeni korištenja računalne tehnologije u procesu samostalnog učenja sviranja seta bubnjeva, ili šire,

glazbenih instrumenta. Istraživanje je vrlo praktično te bi se na ovim osnovama moglo razviti praktično rješenje koje bi se moglo primijeniti u praksi i potaknuti korisnike na vlastiti razvoj u domeni glazbene umjetnosti.

LITERATURA

Addictive Drums. (2015, travanj 21.). Dostupno na:

<https://www.xlnaudio.com/addictivedrums>

AdLib. (2015, ožujak 15.). Dostupno na: <http://www.vgmpf.com/Wiki/index.php?title=AdLib>

Arturia SparkLE. (2015, svibanj 5.) Dostupno na:

<https://www.arturia.com/products/drums/sparkle>

Auralia 4. (2015, travanj 12.). Dostupno na: <https://www.risingsoftware.com/auralia/>

Bayraktar, S. (2001). A meta-analysis of the effectiveness of computer-assisted instruction in science education. *Journal of research on technology in education*, 34(2), 173-188.

Bass Method. (2015, travanj 24.) Dostupno na: <http://www.emediamusic.com/bass-lessons/bass-method.html>

Bellman, R. E. (1978). *An Introduction to Artificial Intelligence: Can Computers Think?* Boyd & Fraser Publishing Company, San Francisco.

BFD 3. (2015, svibanj 7.). Dostupno na: <https://www.fxexpansion.com/products/bfd3/>

Brandao, M., Wiggins, G., & Pain, H. (1999). Computers in music education. *In Proceedings of the AISB'99 Symposium on Musical Creativity*, 82-88.

Brusilovsky, P. (1999). Adaptive and intelligent technologies for web-based education. *Kunstliche Intelligenz*, 13(4), 19-25.

Brusilovsky, P., & Peylo, C. (2003). Adaptive and intelligent web-based educational systems. *International Journal of Artificial Intelligence in Education*, 13, 159-172.

CAI. (2014). In *Encyclopedia Britannica*. Pristupio 20. ožujka 2015, na: <http://www.britannica.com/topic/computer-assisted-instruction>

CAI, Computer Assisted Instruction (2015, ožujak 20.). Dostupno na: [http://wikieducator.org/Computer_Assisted_Instruction_\(CAI\)](http://wikieducator.org/Computer_Assisted_Instruction_(CAI))

Cakir, E., Heittola, T., Huttunen, H. & Virtanen, T. (2015). Polyphonic sound event detection using multi label deep neural networks. *In IEEE Neural Networks (IJCNN), 2015 International Joint Conference*, 1-7.

Can Rocksmith 2014 Really Teach You to Play Guitar? (2015, travanj 29.) Dostupno na: <http://www.popularmechanics.com/culture/gaming/a11192/can-rocksmith-2014-really-teach-you-to-play-guitar-17098663/>

Celemony. (2015, travanj 26.) Dostupno na: <http://www.celemony.com/en/melodyne/technology>

Chan, Y. F., Ma, H. K., Chan, F. T., Chen, H. Y., & Chen, T. Y. (1995). Teaching family planning with expert system. *Computers & Education*, 24(4), 293-298.

Commodore 64 programmer's reference guide. (2015, ožujak 15.). Dostupno na: <http://www.classiccmp.org/cini/pdf/Commodore/C64%20Programmer's%20Reference%20Guide.pdf>

Corbett, A. T., Koedinger, K. R., & Anderson, J. R. (1997). Intelligent tutoring systems. *Handbook of human-computer interaction*, 849-874, Amsterdam, Elsevier.

Cruces, A. L. L., & De Arriaga, F. (2000). Reactive agent design for intelligent tutoring systems. *Cybernetics & Systems*, 31(1), 1-47.

Csikszentmihalyi, M. (1990). *Flow: The psychology of optimal experience*. New York, HarperPerennial.

Csikszentmihalyi, M. (1997). *Flowing: The Psychology of Engagement with Everyday Life*. New York, Basic Books.

Dabolins, J. (2012). Trends of the Usage of Adaptive Learning in Intelligent Tutoring Systems. *Databases and Information Systems, Baltic DB&IS*, 191-196.

Dannenberg, R. B., Sanchez, M., Joseph, A., Capell, P., Joseph, R., & Saul, R. (1990). A computer-based multi-media tutor for beginning piano students. *Journal of New Music Research*, 19(2-3), 155-173.

Dannenberg, R. B., Sanchez, M., Joseph, A., Joseph, R., Saul, R., & Capell, P. (1993). Results from the piano tutor project. *In Proceedings of the Fourth Biennial Arts and Technology Symposium*, 143-150.

Deci, E. L., & Ryan, R. M. (2011). Self-determination theory, *Handbook of theories of social psychology*, 1, 416-433.

Denis, G., & Jouvelot, P. (2005). Motivation-driven educational game design: applying best practices to music education. *In Proceedings of the 2005 ACM SIGCHI International Conference on Advances in computer entertainment technology*, 462-465.

Dick, W., Carey, L., & Carey, J. O. (2005). *The systematic design of instruction*. New Jersey, Pearson.

DirectSound. (2015, ožujak 15.). Dostupno na:
[https://msdn.microsoft.com/en-us/library/windows/desktop/bb318665\(v=vs.85\).aspx](https://msdn.microsoft.com/en-us/library/windows/desktop/bb318665(v=vs.85).aspx)

DT-1. (2015, svibanj 2.) Dostupno na: <https://www.roland.com/global/products/dt-1/>

eMedia. (2015, travanj 27.) Dostupno na: <http://www.emediamusic.com/>

Enabling great audio experiences in Windows 10. (2015, ožujak 15.). Dostupno na:
<http://video.ch9.ms/sessions/winhec/2015/files/WHT202%20-%20Enabling%20Great%20Audio%20Experiences%20in%20Windows%2010.pptx>

Farbood, M. (2001). *Hyperscore: a new approach to interactive, computer-generated music*, PhD Thesis, Massachusetts Institute of Technology. Dostupno na:
http://opera.media.mit.edu/papers/Masters_Mary.pdf

Farbood, M. M., Pasztor, E., & Jennings, K. (2004). Hyperscore: a graphical sketchpad for novice composers. *Computer Graphics and Applications, IEEE*, 24(1), 50-54.

Fast Groove Builder. (2015, lipanj 8.) Dostupno na:
<https://www.yumpu.com/en/document/view/11393657/builder-learn-to-play-drums-with-drummers-ebooks/19>

Ferneda, E., Costa, E. D. B., de Almeida, H. O., Rodrigues, D. G., & de Almeida, E. S. (2004). A web-based cooperative e-learning environment for musical harmony domain. *In Proceedings of the 3rd IASTED International Conference on Web-Based Education*, 43-47.

Ferrari, L., Addressi, A. R., & Pachet, F. (2006). New technologies for new music education: The Continuator in a classroom setting. *In Proceedings of ICMPC9 and 6th ESCOM Conference, Bononia University Press, Bologna*.

Finney, J., & Burnard, P. (2010). *Music education with digital technology*. Bloomsbury Publishing.

Fober, D., Letz, S., & Orlarey, Y. (2007). VEMUS-Feedback and groupware technologies for music instrument learning. *In Proceedings of the 4th Sound and Music Computing Conference SMC*, 7, 117-123.

Friend Jam. (2015, travanj 29.) Dostupno na: <http://roland.com/FriendJam/>

Fu, Y., & Shen, R. (2004). GA based CBR approach in Q&A system. *Expert Systems with Applications*, 26(2), 167-170.

Gardan, N., & Gardan, Y. (2003). An application of knowledge based modelling using scripts. *Expert systems with Applications*, 25(4), 555-568.

Gaser, C., & Schlaug, G. (2003). Brain structures differ between musicians and non-musicians. *The Journal of Neuroscience*, 23(27), 9240-9245.

General MIDI. (2015, ožujak 15.). Dostupno na:
<http://www.midi.org/techspecs/gm1sound.php>

Gerry, D., Unrau, A., & Trainor, L. J. (2012). Active music classes in infancy enhance musical, communicative and social development. *Developmental science*, 15(3), 398-407.

GNU Solfege. (2015, travanj 10.) Dostupno na: <https://www.gnu.org/software/solfege/>

Goertzel, B. (2007). *Artificial general intelligence*. Springer, New York.

Gooding, L. F., Abner, E. L., Jicha, G. A., Kryscio, R. J., & Schmitt, F. A. (2014). Musical training and late-life cognition. *American journal of Alzheimer's disease and other dementias*, 29(4), 333-343.

Griffiths, M. D., Davies, M. N., & Chappell, D. (2003). Breaking the stereotype: The case of online gaming. *CyberPsychology & Behavior*, 6(1), 81-91.

Guerin, R. (2005). *MIDI Power!: The Comprehensive Guide (Power!)*. Course Technology Press.

Guitar Method. (2015, travanj 24.) Dostupno na: <http://www.emediamusic.com/guitar-lessons/beginning-guitar-method.html>

Hagen, S. (2004). The effects of computer assisted instruction and cognitive style on sight playing among university group piano students. *Journal of Technology in Music Learning*, 2(2), 44-55.

Harmonix. (2015, travanj 27.) Dostupno na: <http://www.harmonixmusic.com/>

- Hatzilygeroudis, I., & Prentzas, J. (2004). Using a hybrid rule-based approach in developing an intelligent tutoring system with knowledge acquisition and update capabilities. *Expert systems with applications*, 26(4), 447-492.
- Ho, W. C. (2006). Students' experiences with and preferences for using information technology in music learning in Shanghai's secondary schools. *British Journal of Educational Technology*, 38(4), 699-714.
- Howell, D. (2012) *Statistical methods for psychology*. Cengage Learning. Belmont. USA.
- Hughes, J. R., Daaboul, Y., Fino, J. J., & Shaw, G. L. (1998). The "Mozart effect" on epileptiform activity. *Clinical EEG (electroencephalography)*, 29(3), 109-119.
- Hyde, K. L., Lerch, J., Norton, A., Forgeard, M., Winner, E., Evans, A. C., & Schlaug, G. (2009). Musical training shapes structural brain development. *The Journal of Neuroscience*, 29(10), 3019-3025.
- Jackson, S. A., & Eklund, R. C. (2002). Assessing flow in physical activity: The Flow State Scale-2 and Dispositional Flow Scale-2. *Journal of Sport & Exercise Psychology*, 24(2), 133-150.
- Jackson, S. A., & Marsh, H. W. (1996). Development and validation of a scale to measure optimal experience: The Flow State Scale. *Journal of sport and exercise psychology*, 18(1), 17-35.
- Jam Origin. (2015, travanj 26.) Dostupno na: <http://jamorigin.com/technology/>
- Jennings, K. (2005). Hyperscore: A case study in computer mediated music composition. *Education and Information Technologies*, 10(3), 225-238.
- Kent State University: One-Way ANOVA. (2016, rujun 15.) Dostupno na: <http://libguides.library.kent.edu/SPSS/OneWayANOVA>
- Klimmt, C. (2003). Dimensions and determinants of the enjoyment of playing digital games: A three-level model. *In Level up: Digital games research conference*, 246-257.
- Konecki, M. (2014). Learning to play musical instruments through dynamically generated lessons in real-time based on adaptive learning system. *Proceedings of the 25th Central European Conference on Information and Intelligent Systems*, 124-129.

- Konecki, M. (2015a). Self-Paced Computer Aided Learning of Music Instruments. *Proceedings of the 38th International Convention on Information and Communication Technology, Electronics and Microelectronics*, 910-914.
- Konecki, M. (2015b). Adaptive drum kit learning system: User interface properties and features. *18th International Multiconference Information Society- IS 2015, VIVID 2015*, 228-236.
- Konecki, M. (2015c). Adaptive drum kit learning system: Advanced playing errors detection. *Proceedings of the 18th International Multiconference Information Society - IS 2015, Volume A, Intelligent Systems*, 58-62.
- Koster, R. (2013). *Theory of fun for game design*. California, O'Reilly Media, Inc.
- Kraus, N., & Chandrasekaran, B. (2010). Music training for the development of auditory skills. *Nature Reviews Neuroscience*, 11(8), 599-605.
- Kruskal, W. H., & Wallis, W. A. (1952). Use of ranks in one-criterion variance analysis. *Journal of the American statistical Association*, 47(260), 583-621.
- Kuo, Y., T., & Chuang, M. C. (2013). A proposal of a color music notation system on a single melody for music beginners. *International Journal of Music Education November*, 31(4), 394-412.
- Laerd statistics: One-way ANOVA. (2016, rujan 15.) Dostupno na:
<https://statistics.laerd.com/statistical-guides/one-way-anova-statistical-guide-3.php>
- Laird, J. E., Newell, A., & Rosenbloom, R. S. (1987). Soar: An architecture for general intelligence. *Artificial intelligence*, 33(1), 1-64.
- LenMus. (2015, travanj 21.) Dostupno na: <http://www.lenmus.org/mws/noticias>
- Lerch, D., & Anderson, T. (2000). The Mozart effect: A closer look. Dostupno na:
http://lrs.ed.uiuc.edu/students/lerch1/edpsy/mozart_effect.html, pristupio: 10.3.2015.
- Levene, H. (1960). *In Contributions to Probability and Statistics: Essays in Honor of Harold Hotelling*, I. Olkin et al. eds. Stanford University Press, 278-292.
- Levy, M. (1997). *Computer-assisted language learning: Context and conceptualization*. Oxford University Press.
- Liao, Y. K. C. (2007). Effects of computer-assisted instruction on students' achievement in Taiwan: A meta-analysis. *Computers & Education*, 48(2), 216-233.

Liao, S. H. (2005). Expert system methodologies and application - a decade review from 1995 to 2004. *Expert systems with applications*, 28(1), 93-103.

List of music video games. (2015, travanj 27.) Dostupno na:

https://en.wikipedia.org/wiki/List_of_music_video_games

Loy, G. (1985). Musicians make a standard: the MIDI phenomenon. *Computer Music Journal*, 9(4), 8-26.

Lu, H., Zhang, B., Wang, Y., & Leow, W. K. (2008, October). iDVT: An interactive digital violin tutoring system based on audio-visual fusion. In *Proceedings of the 16th ACM international conference on Multimedia*, 1005-1006.

Lucas, P. J. & Gaag, L. C. (1991). *Principles of Expert Systems*. Addison-Wesley, Amsterdam, The Netherlands.

Luger, G. F. & Stubblefield, W. A. (1993). *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*. Benjamin/Cummings, Redwood City, California.

Many people wish they had learned to play a musical instrument. (2015, ožujak 10.). Dostupno na: <http://artfacts.australiacouncil.gov.au/music/participation-7/many-people-wish-they-had-learned-to-play-a-musical-instrument/>

Mitra, R. S., & Basu, A. (1997). Knowledge representation in MICKEY: An expert system for designing microprocessor-based system. *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on*, 27(4), 467-479.

Mockler, R. J., Dologite, D. G. & Gartenfeld, M. E. (2000). "Talk with the experts": Learning management decision-making using CAI. *Cybernetics & Systems*, 31(4), 431-464.

Moneta, G. B. (2012). On the measurement and conceptualization of flow. In *Advances in flow reasearch*, Springer, New York.

Moreno, S., Bialystok, E., Barac, R., Schellenberg, E. G., Cepeda, N. J., & Chau, T. (2011). Short-term music training enhances verbal intelligence and executive function. *Psychological science*, 22(11), 1425-1433.

Music Ace 2. (2015, travanj 22.) Dostupno na: <https://www.harmonicvision.com/ma2fact.htm>

NAMM 2010 Global Report: People's attitudes toward music (2015, ožujak 10.) Dostupno na: <http://www.nxtbook.com/nxtbooks/namm/2010globalreport/index.php?startid=154#/134>

Neapolitan, R. E. (2012). *Probabilistic reasoning in expert systems: theory and algorithms*. CreateSpace Independent Publishing Platform.

Neubart, K., Gehrs, V., Sutton, L., Weyde, T., & Poggio, L. (2008). The European Curriculum Challenge: a case study on technology-supported specialised music education. *4th i-Maestro Workshop on Technology-Enhanced Music Education, NIME*, 25-32.

Ng, K., Larkin, O., Koerselman, T., & Ong, B. (2008). Technology-enhanced learning for music with i-maestro framework and tools. *Proceedings of EVA London Conference*, 177-187.

NI Maschine Studio, (2015. svibanj 3.). Dostupno na: <https://www.native-instruments.com/en/products/maschine/production-systems/maschine-studio/>

Nkambou, R., Bourdeau, J., & Mizoguchi, R. (2010). *Advances in intelligent tutoring systems* (Vol. 308). Springer Science & Business Media.

Number of people playing a musical instrument in the U.S. from 2002 to 2010. (2015, ožujak 10.). Dostupno na: <http://www.statista.com/statistics/192834/people-playing-a-musical-instrument-in-the-us/>

Nwana, H. S. (1990). Intelligent tutoring systems: an overview. *Artificial Intelligence Review*, 4(4), 251-277.

Oblinger, D. G. (2004). The next generation of educational engagement. *Journal of interactive media in education*, 2004(8), 1-18.

Pachet, F., & Addressi, A. R. (2004). When children reflect on their own playing style: experiments with continuator and children. *Computers in Entertainment (CIE)*, 2(1), 14-33.

Patston, L. L., Hogg, S. L., & Tippett, L. J. (2007). Attention in musicians is more bilateral than in non-musicians. *Laterality*, 12(3), 262-272.

Percival, G., Wang, Y., & Tzanetakis, G. (2007). Effective use of multimedia for computer-assisted musical instrument tutoring. In *Proceedings of the international workshop on Educational multimedia and multimedia education, ACM*, 67-76.

Phobun, P., & Vicheanpanya, J. (2010). Adaptive intelligent tutoring systems for e-learning systems. *Procedia-Social and Behavioral Sciences*, 2(2), 4064-4069.

Pitts, A., & Kwami, R. M. (2002). Raising students' performance in music composition through the use of information and communications technology (ICT): a survey of secondary schools in England. *British Journal of Music Education*, 19(01), 61-71.

Playground Sessions. (2015, travanj 24.) Dostupno na: <http://www.playgroundsessions.com/>

Polson, M. C., & Richardson, J. J. (2013). *Foundations of intelligent tutoring systems*. Psychology Press, New Jersey.

Prensky, M. (2003). Digital game-based learning. *Computers in Entertainment (CIE)*, 1(1), 21-24.

Puig, V., Guedy, F., Fingerhut, M., Serriere, F., Bresson, J., & Zeller, O. (2005). Musique Lab 2: A three level approach for music education at school. In *Proceedings of the International Computer Music Conference*, 419-422.

Raptis, S., Chalamandaris, A., Baxevanis, A., Askenfeld, A., Schoonderwaldt, E., Hansen, K. F., Foer, D., Letz, S., & Orlarey, Y. (2006). Imutus-an effective practicing environment for music tuition. In *Proceedings of the International Computer Music Conference*, 383-386.

Rich, R. & Knight, K. (1991). *Artificial Intelligence*. McGraw-Hill, New York.

Roblyer, M. (2006). *Integrating Educational Technology into Teaching*. Upper Saddle River, NJ: Pearson Education Inc.

Rocksmith. (2015, travanj 28.) Dostupno na: <http://rocksmith.ubi.com/rocksmith/en-us/home/>

Rocksmith 2014. (2015, travanj 28.) Dostupno na:
https://en.wikipedia.org/wiki/Rocksmith_2014

Rogers, G. L. (1996). Effect of Colored Rhythmic Notation on Music-Reading Skills of Elementary Students. *Journal of Research in Music Education*, 44(1), 15-25.

Roland MT-32. (2015, ožujak 15.). Dostupno na: https://en.wikipedia.org/wiki/Roland_MT-32

Roland Triggers. (2015, travanj 11.) Dostupno na:
<http://www.rolandus.com/blog/2013/01/11/what-are-drum-triggers/>

Ruiz-Sanchez, J. M., Valencia-Garcia, R., Fernandez-Breis, J. T., Martiinez-Bejar, R., & Compton, P. (2003). An approach for incremental knowledge acquisition from text. *Expert Systems with Applications*, 25(1), 77-86.

- Ryan, R. M., & Deci, E. L. (2000). Self-determination theory and the facilitation of intrinsic motivation, social development, and well-being. *American psychologist*, 55(1), 68.
- Russell, S. & Norvig, P. (1995). *Artificial intelligence: a modern approach*. Pearson Education Limited, United Kingdom.
- Scheffe, H. (1999). *The analysis of variance*. Vol. 72. John Wiley & Sons. New York, USA.
- Schellenberg, E. G. (2006). Long-term positive associations between music lessons and IQ. *Journal of Educational Psychology*, 98(2), 457.
- Schellenberg, E. G. (2004). Music lessons enhance IQ. *Psychological Science*, 15(8), 511-514.
- Schlaug, G., Norton, A., Overy, K., & Winner, E. (2005). Effects of music training on the child's brain and cognitive development. *Annals of the New York Academy of Sciences*, 1060(1), 219-230.
- Schoonderwaldt, E., Hansen, K., & Askenfeld, A. (2004). IMUTUS—an interactive system for learning to play a musical instrument. *In Proceedings of the International Conference of Interactive Computer Aided Learning*, 143-150.
- Self-determination theory. (2015, svibanj 4.) Dostupno na:
<http://www.selfdeterminationtheory.org/theory/>
- Shapiro, S. S., & Wilk, M. B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3/4), 591-611.
- Share of adults taking a music lesson or class during their lifetime in the United States from 1982 to 2012. (2015, ožujak 10.). Dostupno na:
<http://www.statista.com/statistics/195460/participation-in-music-classes-and-lessons-in-the-us-since-1982/>
- Shute, V. J., & Zapata-Rivera, D. (2012). Adaptive educational systems. *Adaptive technologies for training and education*, 7(1), 27-61.
- Sitzmann, T., Kraiger, K., Stewart, D., & Wisher, R. (2006). The comparative effectiveness of web-based and classroom instruction: A meta-analysis. *Personnel psychology*, 59(3), 623-664.

Smoliar, S. W., Waterworth, J. A., & Kellock, P. R. (1995). pianoFORTE: a system for piano education beyond notation literacy. *In Proceedings of the third ACM international conference on Multimedia*, 457-465.

Sound Blaster. (2015, ožujak 15.). Dostupno na:

https://en.wikipedia.org/?title=Sound_Blaster

Spaced repetition. (2015, travanj 22.) Dostupno na:

https://en.wikipedia.org/wiki/Spaced_repetition

Stankov, S., Glavinić, V., & Rosić, M. (2010). *Intelligent Tutoring Systems in E-Learning Environments: Design, Implementation and Evaluation*. New York, IGI Global.

Stathacopoulou, R., Magoulas, G. D., & Grigoriadou, M. (1999). Neural network-based fuzzy modeling of the student in intelligent tutoring systems. *In Proceedings of International Joint Conference on Neural Networks*, 5(1), 3517-3521.

Steinberg Story. (2015, ožujak 18.). Dostupno na:

<https://www.steinberg.net/en/company/aboutsteinberg.html>

Steinberg Technologies. (2015, ožujak 18.) Dostupno na:

<https://www.steinberg.net/en/company/technologies.html>

Steinberg, K. C. (2013). Steinberg Audio Streaming Input Output Specification, Dostupno na:

<http://www.steinberg.net/en/company/developers.html>

Steele, K. M., Bass, K. E., & Crook, M. D. (1999). The mystery of the Mozart effect: Failure to replicate. *Psychological Science*, 10(4), 366-369.

Superior Drummer. (2015, svibanj 5.). Dostupno na:

<http://www.toontrack.com/product/superior-drummer-2/>

Tambouratzis, G., Perifanos, K., Voulgari, I., Askenfelt, A., Granqvist, S., Hansen, K. F., Orlarey, Y., Fober, D., & Letz, S. (2008). VEMUS: An integrated platform to support music tuition tasks. *In Advanced Learning Technologies, 2008. ICALT'08. Eighth IEEE International Conference*, 972-976.

The birth of the IBM PC. (2015, ožujak 15.). Dostupno na:

https://www-03.ibm.com/ibm/history/exhibits/pc25/pc25_birth.html

- Vogel, J. J., Vogel, D. S., Cannon-Bowers, J., Bowers, C. A., Muse, K., & Wright, M. (2006). Computer gaming and interactive simulations for learning: A meta-analysis. *Journal of Educational Computing Research*, 34(3), 229-243.
- Von Alan, R. H., March, S. T., Park, J., & Ram, S. (2004). Design science in information systems research. *MIS quarterly*, 28(1), 75-105.
- Warendorf, K., & Tsao, S. J. (1997). Application of fuzzy logic techniques in the BSS1 tutoring system. *Journal of Artificial Intelligence in Education*, 8(1), 113-146.
- Ward, M. (2007) A template for CALL programs for endangered languages. PhD thesis, Dublin City University. Dostupno na: DART-Europe baza disertacija (www.dart-europe.eu)
- WASAPI. (2015, ožujak 15.). Dostupno na:
[https://msdn.microsoft.com/en-us/library/windows/desktop/dd371455\(v=vs.85\).aspx](https://msdn.microsoft.com/en-us/library/windows/desktop/dd371455(v=vs.85).aspx)
- Webster, P. R. (2007). Computer-based technology and music teaching and learning: 2000–2005. In *International handbook of research in arts education*, 1311-1330.
- Weyde, T. (2006). Generation of Exercises and Exercise Sequences for Technology-Enhanced Music Education. In *Axmedis 2006: Proceedings of the 2nd International Conference on Automated Production of Cross Media Content for Multi-channel Distribution*, Firenze University Press, 126-131.
- Wilcox, R. (2005). Kolmogorov–smirnov test. *Encyclopedia of biostatistics*.
- Winston, R. H. (1992). *Artificial Intelligence*. Addison-Esley, Reading, Massachusetts.
- Yang, P. (2015). The impact of music on educational attainment. *Journal of Cultural Economics*, 39(117), 1-28.
- Yin, J., Wang, Y., & Hsu, D. (2005, November). Digital violin tutor: an integrated system for beginning violin learners. In *Proceedings of the 13th annual ACM international conference on Multimedia*, 976-985.
- Yinsheng, Z. (2013). Collaborative Mobile-Learning Systems for Music Education and Training, PhD thesis, Fundan University, Shanghai. Dostupno na:
<http://www.scholarbank.nus.edu.sg/>
- Yoshii, K., Goto, M. & Okuno, H. G. (2007). Drum sound recognition for polyphonic audio signals by adaptation and matching of spectrogram templates with harmonic structure suppression. *IEEE Transactions on Audio, Speech, and Language Processing*, 15(1), 333-345.


PRILOZI

Prilog A: Baza znanja - ritmički uzorci.....	i
Prilog B: Završna vježba	viii
Prilog C: Anketa - intrinzična motivacija.....	xi
Prilog D: Anketa - stanje protoka.....	xii
Prilog E: Primjeri pisane evidencije polaznika.....	xiv
Prilog F: Informacije o ekspertu.....	xxi
Prilog G: Dodatni tehnički detalji implementacije prototipa.....	xxii

PRILOG A: BAZA ZNANJA - RITMIČKI UZORCI

Numerirani notni zapis svih ritmičkih uzoraka koji se nalaze u bazi znanja.

Korištene oznake prstometa: D - desna ruka, L - lijeva ruka



Vježbe na malom bubnju

1 2 3 4

5 6 7 8

9 10 11 12

13 14 15 16

17 18

Varijacije prstometa - pojedinačni udarci, dvostruki udarci, jednostruki paradidl

D L D L D L D L D D L L D D L L D L D D L D L L

19 20 21

Osnovni ritam - četvrtinke

22 23 24 25

26 27 28 29

30 31 32

Osnovni ritam - osminke

33 34 35 36

37 38 39 40

41 42 43

Osnovni ritam - off-beat

44 45 46 47

48 49 50 51

52 53 54

Varijacije - četvrtinke

55 56 57 58

59 60

Varijacije - osminke

61 62 63 64

65 66

Varijacije - off-beat

67 68 69 70

71 72

Half-time ritam - četvrtinke

73 74 75 76

77 78

Half-time ritam - osminke

79 80 81 82

83 84


Half-time ritam - off-beat

85 86 87 88

89 90


Solo dionice - jednostruki udarci

D L D L D L D L itd.





Solo dionice - dvostruki udarci

D D L L D D L L itd.






Solo dionice - jednostruki paradidl

D L D D L D L L itd.




Solo varijacije - pedal bas





Melodijski uzorci



141 142 143 144

The image shows a musical score for measures 141 through 144. The notation is written on a grand staff with two staves. The key signature is one flat (B-flat) and the time signature is 4/4. The music features a complex rhythmic pattern with many eighth and sixteenth notes, often beamed together. There are also rests and some notes marked with an 'x'. The measures are numbered 141, 142, 143, and 144 below the staff.

PRILOG B: ZAVRŠNA VJEŽBA

Završna vježba putem koje se vršila evaluacija sustava, ista za sve ispitanike.

Završna vježba

The image displays seven staves of musical notation, each representing a different exercise in a final exercise set. All staves are in 4/4 time, indicated by the '4' over the '4' in the time signature. The notation is written on a grand staff (treble and bass clefs) with a key signature of one sharp (F#). The exercises are as follows:

- Staff 1:** Features a sequence of eighth notes in the treble clef, starting with a half rest in the bass clef. The pattern repeats for the first three measures, followed by a final measure with a different eighth-note sequence.
- Staff 2:** Similar to Staff 1, but with a different eighth-note sequence in the final measure.
- Staff 3:** Features a sequence of eighth notes in the treble clef, starting with a half rest in the bass clef. The pattern repeats for the first three measures, followed by a final measure with a different eighth-note sequence.
- Staff 4:** Similar to Staff 3, but with a different eighth-note sequence in the final measure.
- Staff 5:** Features a sequence of eighth notes in the treble clef, starting with a half rest in the bass clef. The pattern repeats for the first three measures, followed by a final measure with a different eighth-note sequence.
- Staff 6:** Similar to Staff 5, but with a different eighth-note sequence in the final measure.
- Staff 7:** Features a sequence of eighth notes in the treble clef, starting with a half rest in the bass clef. The pattern repeats for the first three measures, followed by a final measure with a different eighth-note sequence.

The image displays eight staves of musical notation, each in 4/4 time. The notation is written on a five-line staff with a treble clef and a key signature of one sharp (F#). The music consists of various rhythmic patterns, including eighth notes, quarter notes, and rests. Some staves feature a series of 'x' marks above the notes, possibly indicating a specific performance technique or a placeholder for a melody. The notation is arranged in a vertical sequence, with each staff containing four measures of music.

PRILOG C: ANKETA - INTRINZIČNA MOTIVACIJA

Za svaku tvrdnju, ispitanik je trebao izraziti razinu slaganja prema sljedećoj skali:

1	2	3	4	5	6	7
Uopće nije točno	Nije točno	Više netočno nego točno	Niti točno, niti netočno	Više točno nego netočno	Točno	U potpunosti točno

1. Vjerujem da bih mogao imati koristi od izvršavanja ove aktivnosti.
2. Vjerujem da sam u nekoj mjeri imao izbor hoću li izvršiti ovu aktivnost.
3. Dok sam izvršavao ovu aktivnost, razmišljao sam o tome kako uživam u njoj.
4. Vjerujem da izvršavanje ove aktivnosti može unaprijediti moju koncentraciju.
5. Bilo je zabavno izvršavati ovu aktivnost.
6. Vjerujem da je ova aktivnost važna za moj razvoj/napredak.
7. Zbilja sam uživao izvršavati ovu aktivnost.
8. Nisam mogao birati hoću li izvršavati ovu aktivnost ili ne.
9. Izvršavao sam ovu aktivnost jer sam to želio.
10. Smatram da je ova aktivnost važna.
11. Dok sam izvršavao aktivnost, uživao sam u njoj.
12. Smatram da je ovo bila izuzetno dosadna aktivnost.
13. Moguće je da bi ova aktivnost mogla unaprijediti moje navike učenja.
14. Osjećao sam se kao da nemam drugog izbora nego jednostavno izvršiti ovu aktivnost.
15. Smatram da je ovo bila jako zanimljiva aktivnost.
16. Voljan sam ponovno izvršavati ovu aktivnost jer smatram da je bila korisna.
17. Opisao bih ovu aktivnost kao jako ugodnu aktivnost za izvršavanje.
18. Osjećao sam se kao da moram izvršiti ovu aktivnost.
19. Vjerujem da izvršavanjem ove aktivnosti mogu ostvariti određene koristi.
20. Vršio sam ovu aktivnost jer sam morao.
21. Vjerujem da mi izvršavanje ove aktivnosti može pomoći da budem bolji u školi.
22. Dok sam izvršavao ovu aktivnost, osjećao sam se kao da imam mogućnost izbora.
23. Ovu aktivnost bih opisao kao vrlo zabavu.
24. Osjećam se kao da izvršavanje ove aktivnosti nije bio moj osobni odabir.
25. Bio bih voljan ponovno izvršiti ovu aktivnost jer u njoj vidim vrijednost za mene.

Za mjerenje intrinzične motivacije koriste se tvrdnje: 3, 5, 7, 11, 12 (obrnuto), 15, 17 i 23.

PRILOG D: ANKETA - STANJE PROTOKA

Za svaku tvrdnju, ispitanik je trebao izraziti razinu slaganja prema sljedećoj skali:

1	2	3	4	5
Uopće nije točno	Nije točno	Niti točno, niti netočno	Točno	U potpunosti točno

1. Doživio sam izazov, ali sam vjerovao da su moje vještine dovoljne da se nosim s izazovom.
2. Činio sam ispravne kretnje bez razmišljanja kako da ih ispravno učinim.
3. Jasno sam znao što želim učiniti.
4. Bilo mi je jasno da sam dobro postupao.
5. Moja pažnja je u potpunosti bila usmjerena na ono što sam radio.
6. Imao sam osjećaj potpune kontrole nad onim što radim.
7. Nisam bio zabrinut time što bi drugi mogli misliti o meni.
8. Imao sam dojam da je vrijeme prolazilo brže (ili sporije).
9. Zbilja sam uživao u ovom iskustvu.
10. Moje sposobnosti su bile dovoljne za rješavanje nastale visoko zahtjevne situacije.
11. Stvari su se jednostavno dešavale automatski.
12. Imao sam jasan pojam o tome što želim učiniti.
13. Bio sam svjestan koliko mi dobro ide.
14. Nije bio problem biti usmjeren na ono što se događalo.
15. Imao sam osjećaj kontrole nad onime što sam radio.
16. Tijekom vježbanja nisam bio zabrinut za kvalitetu svoje izvedbe.
17. Činilo mi se da je vrijeme teklo drugačije od normalnog.
18. Svidio mi se osjećaj izvršavanja aktivnosti i želio bih ga doživjeti ponovno.
19. Osjećao sam se dovoljno kompetentnim kako bih izvršio visoke zahtjeve nastale situacije.
20. Izvršavao sam aktivnost automatski.
21. Znao sam što želim postići.
22. Imao sam dobar pojam o tome koliko dobro izvršavam aktivnosti za vrijeme njihovog provođenja.
23. Bio sam u potpunosti koncentriran.
24. Imao sam osjećaj potpune kontrole.
25. Nisam brinuo o tome na koji način se predstavljam.
26. Imao sam osjećaj da vrijeme stoji dok sam izvršavao aktivnost.

27. Nakon aktivnosti sam se odlično osjećao.
28. Izazov i moja vještina su bili na podjednako visokoj razini.
29. Stvari sam činio spontano i automatski bez razmišljanja.
30. Moji ciljevi su bili jasno definirani.
31. Po načinu izvršavanja aktivnosti sam mogao procijeniti koliko mi dobro ide.
32. Bio sam u potpunosti koncentriran na zadatak koji izvršavam.
33. Osjećao sam da imam potpunu kontrolu nad svojim tijelom.
34. Nisam bio zabrinut o tome što bi drugi mogli misliti o meni.
35. U određenim trenucima sam imao osjećaj da se sve događa usporeno.
36. Doživio sam proživljeno iskustvo kao nešto izuzetno vrijedno.

PRILOG E: PRIMJERI PISANE EVIDENCIJE POLAZNIKA

Legenda oznaka u evidenciji:

Brojke - redni broj pojedinog uzorka koji se vježba

JX - aktivnost "jam session" gdje je X redni broj aktivnosti

SX - aktivnost "sve do sada" gdje je X redni broj aktivnosti

Šifra polaznika: A01

1. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
45	1-18

2. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	J1
35	22-32

3. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
5	22-32
15	J2
25	33-43

4. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
5	33-43
10	J3
30	44-54

5. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
5	44-54
15	J4
15	S1
10	55-60

6. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15	55-72
15	J5
12	J2
8	73-77

7. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20	73-90
10	J6
15	S3

8. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
35	91-108
10	J7

9. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15	S4
25	109-120
5	J8

10. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	S5
35	121-144

Šifra polaznika: A02

1. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
35 10	1-18 31

2. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 31 → 35	19-30

3. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20 15 10	22-32 32-36

4. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20 20 5	33-43 33 44-47

5. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20 20 5	44-54 54 51

6. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 35	51 55-72

7. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15 15 15	15 52 73-82

8. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15 10 10	73-90 96 53

9. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
30 10 5	91-108 17 84

10. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
25 10 5 5	109-120 98 55 121-127

Šifra polaznika: R01

1. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
25	1-18
20	J1

2. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
45	19-28

3. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20	22-32
15	J2
10	33-36

4. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15	33-43
15	J3
15	44-50

5. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	50-54
15	J4
10	S1
10	55-60

6. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20	55-72
15	J5
10	S2

7. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	73-78
15	J6
10	S3
10	91-96

8. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20	91-108
15	J7
10	S4

9. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15	109-120
15	J8
10	S5
5	121-125

10. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
30	121-144
10	J9
5	S5

Šifra polaznika: R02

1. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
30 15	1-18 J1

2. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
25 10 10	19-32 J2 33-43

3. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 15 20	33-43 J3 44-54

4. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 5 25	J4 S1 55-72

5. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 10 25	J5 S2 73-90

6. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 5 30	J5 S3 91-108

7. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15 10 20	J7 S4 109-120

8. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15 10 20	J8 S5 121-128

9. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
30 15	121-144 J9

10. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 15 20	121-144 J9 S6

Šifra polaznika: R02

1. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
30 15	1-18 J1

2. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
25 10 10	19-32 J2 33-43

3. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 15 20	33-43 J3 44-54

4. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 5 25	J4 S1 55-72

5. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 10 25	J5 S2 73-90

6. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 5 30	J5 S3 91-108

7. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15 10 20	J7 S4 109-120

8. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15 10 20	J8 S5 121-128

9. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
30 15	121-144 J9

10. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10 15 20	121-144 J9 S6

Šifra polaznika: V01

1. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
30	1-18
10	J1
5	19-23

2. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20	22-32
22	J2
15	33-43
10	

3. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
15	J3
20	44-54
10	J4

4. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	S1
30	55-72
5	J5

5. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
5	S2
25	73-90
10	J6
5	S3

6. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20	91-108
20	J7
5	S4

7. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	S4
30	109-120
5	J8

8. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
5	S5
40	121-144

9. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20	J9
25	S6

10. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	J8
10	S5
10	J9
15	S6

Šifra polaznika: V02

1. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
20	1 - 18
15	✓1
10	19 - 24

2. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
30	22 - 32
15	✓2

3. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	✓2
35	33 - 43

4. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	✓3
30	44 - 54

5. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	44 - 54
15	✓4
10	✓1
10	55 - 61

6. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
25	55 - 72
20	✓5

7. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	✓5
10	52
25	73 - 90

8. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
10	✓6
10	53
25	91 - 104

9. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
5	105 - 108
15	✓7
10	54
15	109 - 115

10. SAT

Vrijeme (min)	Sadržaj (uzorci, J, S)
5	116 - 120
10	✓8
5	55
25	121 - 135

PRILOG F: INFORMACIJE O EKSPERTU

Ekspert koji je sudjelovao u izradi baze znanja i u evaluacijskom procesu je Abel Kovačević (<http://www.ritampercussion.com>).

U dobi od 8 godina počinje svirati bubnjeve i pohađati privatne satove bubnjeva kod Roberta Jambrošića. Godine 1995. zajedno sa svojim bratom i prijateljima osniva “Intro bend” sa kojima je nastupao diljem Hrvatske. 2002. priključuje se Big Band-u Čakovec u kojem je i danas aktivan član.

2007. upisuje Jazz Akademiju u Grazu u klasi Howorda Curtisa gdje je i diplomirao 2011. godine. 2012. završava Učiteljski fakultet u Zagrebu i stiče potvrdu o pedagoško-psihološko-didaktičko-metodičkoj izobrazbi. Svoje iskustvo u radu stiče godinama na različitim glazbenim radionicama, privatnim satovima, osnovnoj i srednjoj školi.

Tijekom karijere održao je brojne nastupe na festivalima i koncertnim dvoranama u SAD-u, Njemačkoj, Kini, Austriji, Švicarskoj, Nizozemskoj, Švedskoj, Mađarskoj, Makedoniji, Francuskoj, Sloveniji, Češkoj, Slovačkoj, Bjelorusiji, Ukraini, Rumunjskoj, Srbiji, BIH.

Učio je svirati od svjetski poznatih bubnjara: Adam Newsbom, John Raily, Jimmy Cobb, Jeff Balard, Billy Hart. Svira s October Light-om i Scifidelity Orchestra s kojima je često na kraćim Europskim turnejama. Godinama je već aktivan kao studijski muzičar.

Proteklih godina surađivao sa mnogo domaćih i stranih glazbenika: Nina Badrić, Alan Bjelinski, Mladen Bodalec, Mark Boling, Luis Bonilla, Matija Dedić, Oliver Dragojević, Ante Gelo, Igor Geržina, Primož Grašić, Stjepko Gut, Jon Hamar, Jacques Houdek, Ivana i Marija Husar, Tereza Kesovija, Zdenka Kovačiček, Boško Petrović, Tom Richeson, Maya Sar, Elvis Stanić, Greg Tardy, Zagrebačka filharmonija, i mnogi drugi.

PRILOG G: DODATNI TEHNIČKI DETALJI IMPLEMENTACIJE PROTOTIPA

Operacijski sustav

Budući da je Windows najrasprostranjeniji operacijski sustav na stolnim računalima (preko 80% računala koristi ovaj operacijski sustav), kreirani prototip je moguće koristiti na tom operacijskom sustavu. Glavni razlog zašto je razvijeno rješenje za operacijski sustav Windows je činjenica da se u budućnosti kreirani konceptualni model i kreirani prototip planiraju i dalje razvijati kako bi se došlo do rješenja koje bi se moglo koristiti u široj primjeni. Razvojem aplikacije na ovom operacijskom sustavu se već u ovom trenutku pokriva najveći dio tržišta potencijalnih korisnika. Cilj je bio stvoriti aplikaciju koja bi bila hibrid između računalne igre i edukacijskog softvera a 95% računalnih igara koje se igraju na stolnim računalima je razvijeno za operacijski sustav Windows što ga čini najprikladnijom platformom i za proizvod koji je razvijen u okviru ove disertacije.

Korišteni programski jezici i programske razvojne okoline: ActionScript i Visual Basic

Cijeli prototip je kreiran u programskom alatu Adobe Animate, u programskom jeziku ActionScript, osim dijela koji se odnosi na MIDI komunikaciju. S obzirom da ActionScript nema podršku za komunikaciju s MIDI uređajima, taj dio je napravljen u programskom jeziku Visual Basic u programskom alatu Visual Studio.

Glavni razlog za odabir programskog alata Adobe Animate (i programskog jezika ActionScript) za izradu sustava je činjenica da se u razvojnoj okolini Adobe Animate-a može napraviti gotovo sva potrebna grafika (sve osim bitmap grafike), a moguće je kreirati i animacije s ugrađenom programskom logikom. Adobe Animate ima odličnu podršku za kreiranje vektorske grafike kao i za animiranje iste a ActionScript je objektno orijentirani programski jezik koji je izuzetno sličan programskom jeziku C++. Uz to, aplikacije kreirane na ovaj način mogu koristiti grafičke kartice za potrebe renderiranja sadržaja.

MIDI komunikacija

Winmm.dll je modul sučelja za programiranje multimedijских aplikacija u operacijskom sustavu Windows. Taj modul omogućava korištenje funkcija niske razine vezane uz zvuk i

igrače kontrolere. Svaki MIDI uređaj nije ništa drugo nego ulazni kontroler, stoga je putem tog modula ostvarena komunikacija s ulaznim uređajima tj. električnim bubnjevima. Na ulazu se dohvaćaju dva podatka: koji element seta bubnjeva je udaren i kojom jačinom. Na temelju tih informacija generiraju se događaji na tipkovnici a to su događaji ulazne jedinice koju ActionScript prepoznaje te se na ovaj način ostvaruje komunikacija s ostatkom aplikacije napravljene u Adobe Animate-u.

U istraživanju su se koristili Rolandovi električni bubnjevi. Svaki set je parametriziran na način da je testirana osjetljivost svakog elementa bubnjarskog seta te je na temelju dobivenih vrijednosti jačine određeno i utvrđeno kada je element slabo, normalno ili prejako udaren.

Tablica G.1. Mapiranje MIDI informacija za električni set bubnjeva Roland TD1KV

Set bubnjeva	Raspon slabog udarca i generirani pritisak tipke	Raspon normalnog udarca i generirani pritisak tipke	Raspon prejakog udarca i generirani pritisak tipke
Pedal bas	0 - 80, tipka "Y"	81 - 120, tipka "X"	121 - 127, tipka "C"
Hihat	0 - 50, tipka "U"	51 - 100, tipka "I"	101 - 127, tipka "O"
Mali bubanj	0 - 60, tipka "A"	61 - 100, tipka "S"	101 - 127, tipka "D"
12' tom	0 - 70, tipka "R"	71 - 110, tipka "T"	111 - 127, tipka "Z"
13' tom	0 - 70, tipka "F"	71 - 110, tipka "G"	111 - 127, tipka "H"
16' tom	0 - 70, tipka "V"	71 - 110, tipka "B"	111 - 127, tipka "N"
"Crash" činela	0 - 50, tipka "M"	51 - 100, tipka ", "	101 - 127, tipka ". "
"Ride" činela	0 - 50, tipka "J"	51 - 100, tipka "K"	101 - 127, tipka "L"

Izrada multimedijски elemenata

Većina vizualnih elemenata aplikacije je kreirana kao vektorska grafika unutar Adobe Animate-a: najznačajniji elementi su grafičko sučelje odabira lekcija te notno crtovlje sa svim elementima koji se unutar notnog crtovlja pojavljuju. Sve animacije (osim animacije na početnom zaslonu) su kreirane unutar istog alata kroz animiranje MovieClip-ova. Animacija na početnom ekranu je kreirana u alatu Adobe After Effects.

Za kreiranje i obradu bitmap grafike korišten je alat Adobe Photoshop. Najznačajniji dio je virtualni prikaz seta bubnjeva koji je kreiran u Adobe Photoshopu. Generalni dizajn cijelog sustava je u početnoj fazi izrade kreiran u istom alatu.

Video materijali snimani su DSLR video kamerom Canon EOS Rebel T2i. Obrada video zapisa i njihova finalna produkcija napravljena je u alatu Adobe After Effects. Za snimanje zvukova u video materijalima korišten je virtualni instrument Addictive Drums.

Pohrana podataka

Multimedijski podatci koje aplikacija koristi nalaze se lokalno na disku u direktoriju aplikacije. Prototip sadrži 164 video zapisa koji zauzimaju 1,3 GB prostora na disku: 144 video zapisa sviranja ritmičkih uzoraka i 20 instrukcijskih video zapisa. Video zapisi su kodirani H.264 video kodekom te su snimljeni u formatu mp4. Osim video zapisa na disku se nalaze i zvučni zapisi semplova seta bubnjeva: 81 zvučni zapis veličine 25 MB. U prototipu je sempliran jedan set bubnjeva te je svaki element seta bubnjeva sempliran po tri puta za tri različite jačine udaraca. Zvučni zapisi su snimljeni u formatu wav, bez kompresije.

Podatci o korisnicima i njihovom napretku se spremaju na disk putem Adobe Animate sustava za pohranu male količine podataka kao SharedObject elementi. Za svakog korisnika prototipa kreirana je posebna datoteka na disku koja korisniku nije vidljiva već je kodirana i pospremljena na posebnoj lokaciji. S obzirom da su podatci koji se spremaju o korisnicima niz numeričkih vrijednosti, datoteke s ovim podacima su relativno male veličine što čini ovakav odabir načina pohrane prikladnim.

Za svakog korisnika pamti se 2080 numeričkih podataka putem kojih se prati koje sve aktivnosti je korisnik izvršio, s kojom razinom uspješnosti je naučen svaki pojedini ritmički uzorak itd. Na temelju tih numeričkih vrijednosti putem različitih vizualnih elemenata korisniku se daje povratna informacija o uspješnosti. Većina tih podataka se korisniku prikazuje putem ekrana za biranje lekcija dok se pojedini specifični podatci nalaze i u drugim aktivnostima.

Analiza podataka i usmjeravanje korisnika

Tijekom provedenog istraživanja nad prikupljenim podacima vršila se elementarna statistička analiza (računanje srednje vrijednosti i standardne devijacije) kako bi se korisnika usmjeravalo kroz vježbe i davala povratna informacija o uspješnosti. U preostalim slučajevima radila se parametrizacija određenih varijabli koje su podešene u fazi testiranja u suradnji s ekspertom. Primjerice, s kojom razinom točnosti uzorak mora biti odsviran kako bi

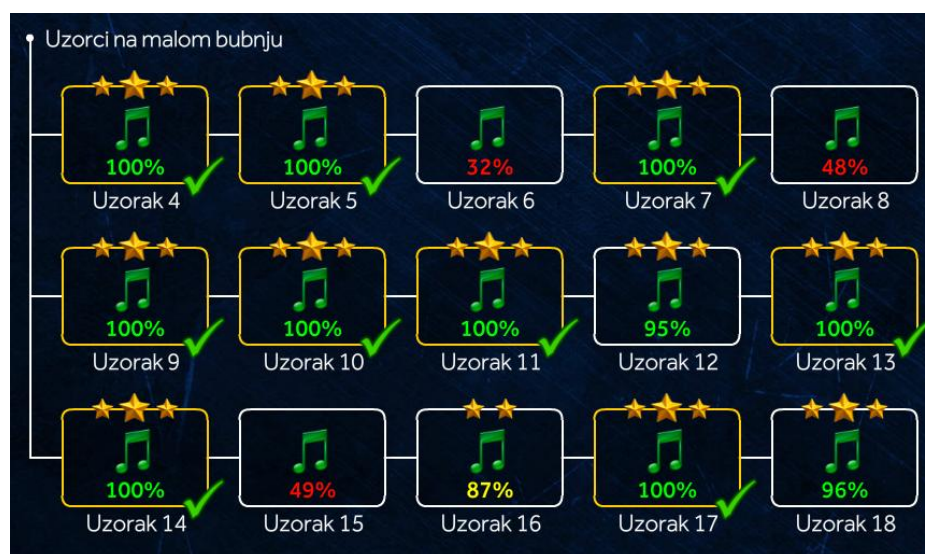
bio proglašen naučenim, koliko odstupanje od prosjeka treba biti kako bi se greška proglasila učestalom unutar određene kategorije grešaka i sl.

Podatci o greškama na temelju kojih se generiraju aktivnosti vezane uz ispravljanje učestalih grešaka se ne zapisuju trajno na disk već postoje unutar sustava sve dok korisnik ne izađe iz aplikacije. Tablica G.2. prikazuje način obrade vezan uz pojedine tipove grešaka.

Tablica G.2. Obrada i povratna informacija prema vrstama grešaka

Vrsta greške	Obrada	Povratna informacija
Odgovarajuća dinamika nota	Ako je 50% odsviranih nota krive dinamike, prikaži oznake za dinamiku	Povratna informacija o dinamici nota prilikom sviranja
Krivo odsvirana nota	Računanje postotka uspješnosti: sve note u odnosu na krivo odsvirane	Oznaka prilikom sviranja: zeleni krug (dobro), crveni x (krivo)
Odsvirana nota koje nema	Računanje postotka uspješnosti: sve note u odnosu na krivo odsvirane	Oznaka na notnom crtovlju: crveni x
Neodsvirana nota	Računanje postotka uspješnosti: ukupan broj nota u uzorku u odnosu na broj točno odsviranih nota	Postotak uspješnosti sviranja uzorka
Nota odsvirana kasnije/ranije	Statistička analiza: ako je barem 2/3 krivo odsviranih nota odsvirano ranije (usporavanje) ili kasnije (ubrzavanje)	Dodatna lekcija s uputama kako treba pripaziti na metronom i brzinu sviranja
Dinamika ruku/nogu	Statistički značajna razlika u greškama dinamike na temelju vrstu nota	Dodatna lekcija u okviru koje se vježbaju uzorci kod kojih je bilo problema u dinamici
Sinkronizacija nota u isto vrijeme	Ako se otkrije kombinacija udaraca u isto vrijeme kod koje u 2/3 slučajeva postoji ista vrsta kašnjenja, tada se to detektira kao učestala greška	Aktivnost u kojoj se vježbaju uzorci s tom kombinacijom nota koja je detektirana kao učestala greška
Sinkronizacija ruku/nogu	Mjerenje vremena odstupanja nota ovisno o tome koja ruka/noga svira notu: ako je 2/3 slučajeva grešaka određene kombinacije, detektira se učestala greška	Aktivnost u kojoj se vježbaju uzorci s tom kombinacijom nota koja je detektirana kao učestala greška
Problematična kombinacija nota	Ako postoji statistički značajna razlika određene vrste greške u odnosu na sve počinjene greške, tada se ona proglašava učestalom greškom	Dodatna aktivnost gdje se vježbaju uzorci s tom kombinacijom greške koja je proglašena učestalom
Problematična cjelina uzoraka	Statistički značajna razlika u uspješnosti naučenosti uzoraka jedne cjeline u odnosu na sve cjeline koje su učene	Kroz grafičko sučelje u prikazu odabira lekcija
Ubrzavanje/usporavanje	Ako je prilikom sviranja uzorka 50% nota odsvirano krivo i 2/3 nota odsvirano prebrzo ili prekasno, detektira se greška ubrzavanja/usporavanja	Povratna informacija prilikom sviranja uzorka ili aktivnosti, dodatna lekcija kako treba pripaziti na tempo

Sustav kroz sučelje odabira lekcija sugerira koje aktivnosti korisnik treba dalje prolaziti no korisnik ima i slobodu sam birati svoj put. Kroz sučelje korisnik dobiva povratnu informaciju o uspješnosti i to mu pomaže u tome da i sam može odabrati iduću aktivnost. U istraživanju većina različitih grešaka ili problematičnih uzoraka detektirana je i ispravljana automatski zbog izravnih povratnih informacija. Slika G.1. prikazuje takvu situaciju: korisnik je svirao kombinirano uzorke određene kategorije te nakon sviranja može vidjeti koji uzorci nisu do kraja uvježbani. Kroz vizualizaciju podataka u pogledu odabira lekcija lako može prepoznati problematične uzorke.



Slika G.1. Povratna informacija o uspješnosti odsviranih nota unutar pojedine kategorije

Završna lekcija mjeri točno odsvirane uzorke i točno odsvirane note. S obzirom da se sviranje završne vježbe kod svih sudionika istraživanja vršilo u kontroliranim uvjetima, ti podatci su nakon provedba završne vježbe direktno upisivani u bazu podataka u računalnom programu SPSS, koji je korišten za završnu statističku obradu podataka.

Za provedbu anketnih upitnika kreirana je također posebna aplikacija u Adobe Animate-u. Podatci koji su upisani u aplikaciju tokom provođenja anketiranja su također spremni putem SharedObject klase lokalno na disk u šifrirane datoteke. Ovi podaci su kasnije prebačeni u SPSS kako bi se nad njima izvršila završna statistička obrada.

ŽIVOTOPIS

Mladen Konecki rođen je U Pakracu 7. veljače 1985. godine. Osnovnu školu je pohađao u Daruvaru gdje je završio i srednju školu s odličnim uspjehom. Svoje školovanje nastavio je u Varaždinu na Fakultetu organizacije i informatike na kojem je diplomirao 2008. godine.

Nakon završenog fakulteta 2008. godine zaposlio se kao profesor na Elektrostrojarskoj školi Varaždin i te iste godine je položio na Učiteljskom fakultetu u Čakovcu pedagoško-psihološku izobrazbu. 2009. godine zapošljava se kao asistent na Fakultetu organizacije i informatike. U razdoblju od 2009. godine do danas sudjelovao je u izvođenju vježbi iz predmeta Algoritmi, Programiranje 1, Programiranje 2, Strukture podataka, Programiranje i Dizajn programskih proizvoda. Na zadnje dvije studentske ankete ocjenjivanja profesora ostvario je najvišu ocjenu na Fakultetu organizacije i informatike. Autor je 17 znanstvenih radova te je mentorirao preko 50 završnih radova. Sudjelovao je u radu na projektu Automatizacija postupaka projektiranja informacijskih sustava (voditelj prof. dr. sc. Alen Lovrenčić).

U svoje slobodno vrijeme kolega se bavi i audio i video produkcijom te je i u toj domeni ostvario nekoliko zapaženih rezultata: 2003. godine je pobijedio na internet natjecanju skladatelja "BandAMP" sa svojom autorskom skladbom "Blues for my darling", 2004. godine je pobijedio na reality show-u "Coca-cola Music Stars", 2010. godine na festivalu "Darfest" dobiva nagradu za promicanje kulture sa svojom vlastitom skladbom "Daruvar" te 2012. godine na istom festivalu dobiva nagradu publike sa svojom skladbom "Daj mi da se vratim".

Član je tima najuspješnijeg "Kickstarter" projekta u Hrvatskoj na kojem je prikupljeno 120.000 dolara za izradu društvene igre pod imenom "Machina Arcana". U sklopu tog projekta snimio je i vlastiti nosač zvuka pod istim imenom. Član je odbora srednje škole Čakovec te je član i odbora amaterske kazališne udruge "Cornerstone Arts" za koju je preveo nekoliko mjuzikala na hrvatski jezik.

POPIS OBJAVLJENIH RADOVA

Znanstveni radovi u drugim časopisima

Schatten, M., Grd, P., Konecki, M., & Kudelić, R. (2014). Towards a formal conceptualization of organizational design techniques for large scale multi agent systems. *Procedia Technology*, 15, 576-585.

Kudelic, R., Konecki, M., & Lovrencic, A. (2013). Multi-agent information system design and implementation: empirical analysis of IS subsystems execution and development order algorithm. *Journal of software*, 8(7), 1660-1666.

Kudelić, R., Lovrenčić, A., & Konecki, M. (2012). Information system subsystems execution and development order algorithm implementation and analysis. *International Journal of*

Kudelic, R., Lovrencic, A., & Konecki, M. (2011). Automatic determination of information system subsystems execution and development order. *International Review on Computers and Software*, 6(4), 455-461.

Znanstveni radovi u zbornicima skupova s međunar.rec.

Rabuzin, K., Šestak, M., & Konecki, M. (2016, January). Implementing UNIQUE Integrity Constraint in Graph Databases. In *The Eleventh International Multi-Conference on Computing in the Global Information Technology*, 48-53.

Konecki, M. (2015, May). Self-paced computer aided learning of music instruments. In *Information and Communication Technology, Electronics and Microelectronics (MIPRO), 2015 38th International Convention*, 809-813. IEEE.

Konecki, M. (2015, January). Adaptive Drum Kit Learning System: Advanced Playing Errors Detection. In *Proceedings of the 18th International Multiconference Information Society-IS 2015*, 58-62.

Konecki, M. (2015, January). Adaptive drum kit learning system: User interface properties and features. In *18th International Multiconference Information Society-IS 2015, VIVID 2015*, 228-236.

Konecki, M. (2014, January). Learning to play musical instruments through dynamically generated lessons in real-time based on adaptive learning system. In Central European Conference on Information and Intelligent Systems, 124-129.

Orehovacki, T., Radosevic, D., & Konecki, M. (2014, May). Perceived quality of Verificator in teaching programming. In Information and Communication Technology, Electronics and Microelectronics (MIPRO), 2014 37th International Convention, 643-648. IEEE.

Schatten, M., Grd, P., Konecki, M., & Kudelić, R. (2014, July). Towards a formal conceptualization of organizational design techniques for large scale multi agent systems. *Procedia Technology*, 15, 576-585.

Jurišić, M., Kermek, D., & Konecki, M. (2012, May). A review of iterated prisoner's dilemma strategies. In MIPRO, 2012 Proceedings of the 35th International Convention, 1093-1097. IEEE.

Orehovacki, T., Radosevic, D., & Konecki, M. (2012, June). Acceptance of verificator by information science students. In Information Technology Interfaces (ITI), Proceedings of the ITI 2012 34th International Conference, 223-230. IEEE.

Konecki, M., Cingula, M., & Kudelić, R. (2011). Integracija sigurnosti informacijskog i komunikacijskog sustava u korporativno upravljanje. In *Menadžment i sigurnost*, 170-179.

Konecki, M., Kudelić, R., & Lovrenčić, A. (2011, May). Efficiency of lossless data compression. In MIPRO, 2011 Proceedings of the 34th International Convention, 810-815. IEEE.

Kudelić, R., Konecki, M., & Maleković, M. (2011, June). Mind map generator software model with text mining algorithm. In Information Technology Interfaces (ITI), Proceedings of the ITI 2011 33rd International Conference, 487-494. IEEE.

Konecki, M., & Kudelić, R. (2010, July). Justifiability of open source software development. In Central European Conference on Information and Intelligent Systems, 493-499.